

**PREDIKSI HARGA *CRYPTOCURRENCY* BERDASARKAN
MODEL *ARTIFICIAL NEURAL NETWORK***

THESIS

**Oleh:
MUHAMMAD SAHI
NIM. 220605210008**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2023**

**PREDIKSI HARGA *CRYPTOCURRENCY* BERDASARKAN
MODEL *ARTIFICIAL NEURAL NETWORK***

THESIS

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
MUHAMMAD SAHI
NIM. 220605210008**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2023**

**PREDIKSI HARGA *CRYPTOCURRENCY* BERDASARKAN
MODEL *ARTIFICIAL NEURAL NETWORK***

THESIS

**Diajukan Kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
MUHAMMAD SAHI
NIM. 220605210008**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2023**

**PREDIKSI HARGA *CRYPTOCURRENCY* BERDASARKAN
MODEL *ARTIFICIAL NEURAL NETWORK***

THESIS

**Oleh:
MUHAMMAD SAHI
NIM. 220605210008**

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 06 November 2023

Pembimbing I,


Dr. Ghuho Crysdiyan, M. Cs
NIP. 19740424 200901 1 008

Pembimbing II,


Dr. Yunifa Miftachul arif, M. T
NIP. 19830616 201101 1 004

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Ghuho Crysdiyan, M. Cs
NIP. 19740424 200901 1 008

**PREDIKSI HARGA CRYPTOCURRENCY BERDASARKAN
MODEL ARTIFICIAL NEURAL NETWORK**

THESIS

**Oleh:
MUHAMMAD SAHI
NIM. 220605210008**

Telah Dipertahankan di Depan Dewan Penguji Thesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M.Kom)
Tanggal: 06 November 2023

Susunan Dewan Penguji

Penguji Utama : Dr. Ririen Kusumawati, M. Kom
NIP. 19720309 200501 2 002

Ketua Penguji : Dr. Muhammad Faisal, M. T
NIP. 19740510 200501 1 007

Sekretaris Penguji : Dr. Cahyo Crysdian, M. Cs
NIP. 19740424 200901 1 008

Anggota Penguji : Dr. Yunifa Miftachul arif, M. T
NIP. 19830616 201101 1 004

Tanda Tangan

()
()
()
()

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Cahyo Crysdian, M. Cs
NIP. 19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Muhammad Sahi
NIM : 220605210008
Program Studi : Magister Informatika
Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Thesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila di kemudian hari terbukti atau dapat dibuktikan Thesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 06 November 2023

Yang membuat pernyataan,



Muhammad Sahi
NIM. 220605210008

MOTTO

“Syukuri, Nikmati, dan Jalani”

PERSEMBAHAN

Dengan rasa syukur *alhamdulillah rabbil 'alamin*, thesis ini saya persembahkan untuk:

1. Seluruh keluarga tercinta yang selalu memberikan semangat dan doa.
2. Segenap civitas akademika Universitas Islam Negeri Maulana Malik Ibrahim Malang yang telah memberikan kesempatan untuk menambah teknologi dan agama.
3. Segenap mahasiswa Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang diatas kerjasama selama ini.
4. Bapak, Ibu, Saudara, dan rekan-rekan yang tidak dapat saya sebutkan satu persatu hingga thesis ini dapat terselesaikan dengan baik.

KATA PENGANTAR

Assalamualaikum Wr . Wb .

Alhamdulillah, penulis mengucapkan puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan studinya di Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang dan sekaligus menyelesaikan thesis ini dengan baik. Selanjutnya penulis mengucapkan terima kasih, disertai doa dan harapan *Jazakumullah Ahsanal Jaza'* kepada semua pihak yang telah membantu menyelesaikan thesis ini. Penulis ingin mengucapkan terima kasih kepada:

1. Dr. Cahyo Crysdiyan, M.Cs dan Dr. Yunifa Miftachul Arif, MT selaku pembimbing thesis yang telah banyak memberikan bimbingan dan pengalaman berharga.
2. Segenap civitas akademika Program Studi Magister Informatika khususnya seluruh dosen mengucapkan terima kasih atas segala ilmu dan bimbingannya.
3. Keluarga tercinta yang selalu memberikan doa dan semangat.
4. Semua rekan seperjuangan yang telah mendukung dan membantu Penulis menyadari bahwa dalam penyusunan thesis ini masih terdapat kekurangan dan penulis berharap semoga thesis ini dapat memberikan manfaat bagi para pembaca khususnya bagi penulis secara pribadi. *amin ya rabbal alamin.*

Wassalamu'alaikum Wr. Wb .

Malang, 06 November 2023

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
HALAMAN PENGAJUAN.....	ii
HALAMAN PENGAJUAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PENGESAHAN.....	v
HALAMAN PERNYATAAN	vi
MOTTO	vii
PERSEMBAHAN.....	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR	xvi
ABSTRAK.....	xviii
<i>ABSTRACT</i>	xix
خلاصة.....	xx
BAB I PENDAHULUAN.....	1
1.1 Latar belakang	1
1.2 Pernyataan masalah	5
1.3 Tujuan penelitian	5
1.4 Batasan masalah	5
1.5 Manfaat Penelitian.....	6

BAB II	STUDI PUSTAKA.....	7
2.1	Prediksi harga <i>cryptocurrency</i> berdasarkan model ANN.....	7
2.2	Kerangka teoritis	10
BAB III	DESAIN PENELITIAN	14
3.1	Prosedur penelitian	14
3.1.1	Pengumpulan data	15
3.1.2	Rekayasa data.....	16
3.1.3	Desain sistem	18
3.1.3.1	Ekstraksi fitur	26
3.1.3.2	Proses utama	26
3.1.4	Implementasi Sistem	27
3.1.5	Eksperimen.....	27
3.2	Instrumen Penelitian.....	29
BAB IV	MODEL ANN SATU <i>HIDDEN LAYER</i>	31
4.1	Desain.....	31
4.2	Implementasi	35
4.3	Uji coba	36
4.3.1	Pelatihan BP-1A.....	36
4.3.2	Pelatihan BP-1B	38
4.3.3	Pelatihan BP-1C	39
4.3.4	Pelatihan BP-1D.....	41
4.3.5	Pelatihan BP-1E	43
4.3.6	Pelatihan BP-1F	44
4.4	Hasil Prediksi	46

4.5	Kesimpulan.....	46
BAB V MODEL ANN DUA <i>HIDDEN LAYER</i>		48
5.1	Desain.....	48
5.2	Implementasi	52
5.3	Uji coba	53
5.3.1	Pelatihan BP-2A.....	53
5.3.2	Pelatihan BP-2B	55
5.3.3	Pelatihan BP-2C	56
5.3.4	Pelatihan BP-2D.....	58
5.3.5	Pelatihan BP-2E	59
5.3.6	Pelatihan BP-2F	61
5.4	Hasil Prediksi	63
5.5	Kesimpulan.....	63
BAB VI MODEL ANN TIGA <i>HIDDEN LAYER</i>		65
6.1	Desain.....	65
6.2	Implementasi	70
6.3	Uji coba	71
6.3.1	Pelatihan BP-3A.....	71
6.3.2	Pelatihan BP-3B	73
6.3.3	Pelatihan BP-3C	74
6.3.4	Pelatihan BP-3D.....	76
6.3.5	Pelatihan BP-3E	77
6.3.6	Pelatihan BP-3F	79
6.4	Hasil Prediksi	81

6.5 Kesimpulan.....	82
BAB VII PEMBAHASAN.....	83
BAB VIII KESIMPULAN.....	92
8.1. Kesimpulan.....	92
8.2. Keterbatasan dan saran.....	92
DAFTAR PUSTAKA	94
LAMPIRAN.....	94

DAFTAR TABEL

Tabel 2.1 Performa prediksi harga <i>cryptocurrency</i> berbasis model ANN.....	12
Tabel 3.1 Data harga bitcoin	16
Tabel 3.2 Hasil normalisasi data	17
Tabel 3.3 Detail data harga <i>cryptocurrency</i>	18
Tabel 3.4 Ekstraksi fitur	26
Tabel 3.5 Atribut data sebagai variabel target	28
Tabel 3.6 Jumlah node pada setiap <i>hidden layer</i>	28
Tabel 3.7 Kombinasi input pada proses pelatihan	29
Tabel 3.8 Instrumen penelitian.....	29
Tabel 4.1 Parameter model	36
Tabel 4.2 Proses pelatihan BP-1A	36
Tabel 4.3 Proses pelatihan BP-1B.....	38
Tabel 4.4 Proses pelatihan BP-1C.....	39
Tabel 4.5 Proses pelatihan BP-1D	41
Tabel 4.6 Proses pelatihan BP-1E.....	43
Tabel 4.7 Proses pelatihan BP-1F	44
Tabel 4.8 Hasil prediksi model BP-ANN pada strategi pertama	46
Tabel 5.1 Parameter model	53
Tabel 5.2 Proses pelatihan BP-2A	53
Tabel 5.3 Proses pelatihan BP-2B.....	55
Tabel 5.4 Proses pelatihan BP-2C.....	56
Tabel 5.5 Proses pelatihan BP-2D	58
Tabel 5.6 Proses pelatihan BP-2E.....	59
Tabel 5.7 Proses pelatihan BP-2F.....	61
Tabel 5.8 Hasil prediksi model BP-ANN pada strategi kedua.....	63
Tabel 6.1 Parameter model	71
Tabel 6.2 Proses pelatihan BP-3A	71

Tabel 4.3 Proses pelatihan BP-3B.....	73
Tabel 6.4 Proses pelatihan BP-3C.....	74
Tabel 6.5 Proses pelatihan BP-3D	76
Tabel 6.6 Proses pelatihan BP-3E.....	77
Tabel 6.7 Proses pelatihan BP-3F	79
Tabel 6.8 Hasil prediksi model BP-ANN pada strategi ketiga	81
Tabel 7.1 Waktu konvergensi dan hasil pengujian MSE	84
Tabel 7.2 Faktor naik turunnya harga <i>cryptocurrency</i>	87

DAFTAR GAMBAR

Gambar 1.1 Data deret waktu Bitcoin dari tahun 2019 hingga 2021	4
Gambar 2.1 Kerangka teoritis prediksi harga <i>cryptocurrency</i>	11
Gambar 3.1 Prosedur penelitian	15
Gambar 3.2 Desain sistem	18
Gambar 3.3 Arsitektur jaringan pertama model ANN	20
Gambar 3.4 Arsitektur jaringan kedua model ANN	21
Gambar 3.5 Arsitektur jaringan ketiga model ANN	22
Gambar 3.6 Arsitektur model ANN yang diusulkan	25
Gambar 4.1 Desain jaringan model ANN dengan satu <i>hidden layer</i>	31
Gambar 4.2 <i>Flowchart</i> proses pelatihan	32
Gambar 4.3 Nilai loss pelatihan BP-1A	37
Gambar 4.4 Perbandingan harga prediksi dengan data harga aktual BP-1A	37
Gambar 4.5 Nilai loss pelatihan BP-1B	38
Gambar 4.6 Perbandingan harga prediksi dengan data harga aktual BP-1B	39
Gambar 4.7 Nilai loss pelatihan BP-1C	40
Gambar 4.8 Perbandingan harga prediksi dengan harga aktual BP-1C	41
Gambar 4.9 Nilai loss pelatihan BP-1D	42
Gambar 4.10 Perbandingan harga prediksi dengan harga aktual BP-1D	42
Gambar 4.11 Nilai loss pelatihan BP-1E	43
Gambar 4.12 Perbandingan harga prediksi dengan harga aktual BP-1E	44
Gambar 4.13 Nilai loss pelatihan BP-1F	45
Gambar 4.14 Perbandingan harga prediksi dengan harga aktual BP-1F	45
Gambar 4.15 Grafik perbandingan model terbaik pada strategi pertama	47
Gambar 5.1 Desain jaringan model ANN dengan dua <i>hidden layer</i>	48
Gambar 5.2 Nilai loss pelatihan BP-2A	54
Gambar 5.3 Perbandingan harga prediksi dengan data harga aktua BP-2A	54
Gambar 5.4 Nilai loss pelatihan BP –2B	55

Gambar 5.5 Perbandingan harga prediksi dengan data harga aktual BP-2B	56
Gambar 5.6 Nilai loss pelatihan BP-2C	57
Gambar 5.7 Perbandingan harga prediksi dengan data harga aktual BP-2C	57
Gambar 5.8 Nilai loss pelatihan BP-2D	58
Gambar 5.9 Perbandingan harga prediksi dengan data harga aktual BP- 2D	59
Gambar 5.10 Nilai loss pelatihan BP-2E	60
Gambar 5.11 Perbandingan harga prediksi dengan data harga aktual BP-2E.....	61
Gambar 5.12 Nilai loss pelatihan BP-2F	62
Gambar 5.13 Grafik perbandingan model terbaik pada strategi kedua.....	64
Gambar 6.1 Desain jaringan model ANN dengan tiga <i>hidden layer</i>	65
Gambar 6.2 Nilai loss pelatihan BP-3A	72
Gambar 6.3 Perbandingan harga prediksi dengan data harga aktual BP-3A	72
Gambar 6.4 Nilai loss pelatihan BP-3B	73
Gambar 6.5 Perbandingan harga prediksi dengan data harga aktual BP-3B	74
Gambar 6.6 Nilai loss pelatihan BP-3C	75
Gambar 6.7 Perbandingan harga prediksi dengan data harga aktual BP-3C	75
Gambar 6.8 Nilai loss pelatihan BP-3D	76
Gambar 6.9 Perbandingan harga prediksi dengan harga aktual BP-3D.....	77
Gambar 6.10 Nilai loss pelatihan BP-3E	78
Gambar 6.11 Perbandingan harga prediksi dengan harga aktual BP-3E	79
Gambar 6.12 Nilai loss pelatihan BP-3F	80
Gambar 6.13 Perbandingan harga prediksi dengan data harga aktual BP-3F.....	80
Gambar 6.14 Grafik perbandingan model terbaik pada strategi ketiga	82
Gambar 7.1 Perbandingan tingkat performa terbaik arsitektur model ANN	85
Gambar 7.2 Perbandingan waktu konvergensi selama proses pelatihan.....	86

ABSTRAK

Muhammad Sahi. 2023. Prediksi Harga *Cryptocurrency* Berdasarkan Model *Artificial Neural Network*. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing : (I) Dr. Cahyo Crysdiyan, M.Cs. Pembimbing (II) : Dr. Yunifa Miftachul Arif, MT

Kata Kunci: Prediksi, *Cryptocurrency*, *Artificial Neural Network*, *Backpropagation*

Prediksi harga *cryptocurrency* yang akurat sangat penting untuk membantu para trader memperkirakan harga *cryptocurrency* yang berfluktuasi, sehingga diperlukan ketelitian yang tinggi dalam memprediksi harga *cryptocurrency*. *Artificial Neural Network* (ANN) merupakan salah satu model yang cukup populer di bidang IT karena memberikan hasil akurasi terbaik dalam melakukan prediksi. Model ANN sangat ampuh dalam mengenali berbagai pola untuk memodelkan dan memprediksi harga mata uang kripto. Penelitian ini bertujuan untuk mengevaluasi kinerja model ANN dalam memprediksi harga mata uang kripto menggunakan algoritma *backpropagation* (BP). Data yang digunakan sebanyak 476 yang terdiri dari atribut *date*, *open*, *high*, *low*, *close*, *adj-close*, dan *volume*. Penulis melakukan perhitungan dengan menetapkan setiap atribut sebagai variabel target kecuali atribut *date* (D), jumlah lapisan tersembunyi, dan jumlah node pada setiap lapisan. Perhitungan dilakukan berdasarkan variasi arsitektur model untuk memperoleh nilai *mean square error* (MSE). Hasil penelitian menunjukkan bahwa strategi ketiga dengan tiga lapisan tersembunyi (THL) khususnya pada pelatihan BP-3C merupakan model terbaik dibandingkan dengan strategi pertama yang menggunakan satu lapisan tersembunyi (SHL), dan strategi kedua yang menggunakan dua lapisan tersembunyi. layer (DHL), dengan nilai MSE sekitar $3.6412e^{-04}$ atau nilai akurasi sekitar 99.97% dan waktu proses 5 *ms/step*. Hal ini menunjukkan bahwa model THL BP-3C merupakan model yang tepat untuk memprediksi *cryptocurrency*.

ABSTRACT

Muhammad Sahi. 2023. Cryptocurrency Price Prediction Based on Artificial Neural Network Models. Master of Informatics Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Supervisor: (I) Dr. Cahyo Crys dian, M.Cs. Supervisor (II): Dr. Yunifa Miftachul Arif, MT

Keywords: *Prediction, Cryptocurrency, Artificial Neural Network, Backpropagation*

Accurate cryptocurrency price predictions are very important to help traders estimate fluctuating cryptocurrency prices, so high accuracy is needed in predicting cryptocurrency prices. Artificial Neural Network (ANN) is a model that is quite popular in the IT field because it provides the best accuracy results in making predictions. ANN models are very powerful in recognizing various patterns to model and predict cryptocurrency prices. This research aims to evaluate the performance of the ANN model in predicting cryptocurrency prices using the backpropagation (BP) algorithm. The data used was 476, consisting of date, open, high, low, close, adj-close, and volume attributes. The author carries out calculations by setting each attribute as a target variable except the date (D) attribute, the number of hidden layers, and the number of nodes in each layer. Calculations are carried out based on variations in model architecture to obtain the mean square error (MSE) value. The research results show that the third strategy with three hidden layers (THHL), especially in BP-3C training, is the best model compared to the first strategy, which uses one hidden layer (OHL), and the second strategy which uses two hidden layers (THL), with an MSE value of around $3.6412e^{-04}$ or an accuracy value of around 99.97% and a processing time of 5 ms/step. This shows that the THHL BP-3C model is the right model for predicting cryptocurrency prices.

خلاصة

محمد ساهي. 2023. التنبؤ بأسعار العملات المشفرة بناءً على نماذج الشبكات العصبية الاصطناعية. برنامج الماجستير في المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرف: (I) د. كاهيو كريسديان، M.Cs. المشرف (الثاني): د. يونيفة مفتاح عارف، م

الكلمات المفتاحية: التنبؤ، العملة المشفرة، الشبكة العصبية الاصطناعية، الانتشار العكسي

تعد التنبؤات الدقيقة لأسعار العملات المشفرة مهمة جدًا لمساعدة المتداولين على تقدير أسعار العملات المشفرة المتقلبة، لذلك هناك حاجة إلى دقة عالية في التنبؤ بأسعار العملات المشفرة. تعد الشبكة العصبية الاصطناعية (ANN) نموذجًا شائعًا جدًا في مجال تكنولوجيا المعلومات لأنه يوفر أفضل النتائج الدقيقة في عمل التنبؤات. تعتبر نماذج ANN قوية جدًا في التعرف على الأنماط المختلفة لنمذجة أسعار العملات المشفرة والتنبؤ بها. يهدف هذا البحث إلى تقييم أداء نموذج ANN في التنبؤ بأسعار العملات المشفرة باستخدام خوارزمية الانتشار العكسي (BP). كانت البيانات المستخدمة 476، وتتكون من سمات التاريخ، والفتح، والأعلى، والمنخفض، والإغلاق، والإغلاق، والحجم. يقوم المؤلف بإجراء الحسابات عن طريق تعيين كل سمة كمتغير مستهدف باستثناء سمة التاريخ (D)، وعدد الطبقات المخفية، وعدد العقد في كل طبقة. يتم إجراء الحسابات بناءً على الاختلافات في بنية النموذج للحصول على قيمة متوسط مربع الخطأ (MSE). أظهرت نتائج البحث أن الإستراتيجية الثالثة ذات الطبقات الثلاث المخفية (THL)، خاصة في تدريب BP-3C، هي النموذج الأفضل مقارنة بالإستراتيجية الأولى التي تستخدم طبقة مخفية واحدة (SHL)، والإستراتيجية الثانية التي تستخدم طبقتين مخفيتين (SHL). الطبقات (DHL)، بقيمة MSE تبلغ حوالي $3.6412e^{-04}$ أو قيمة دقة تبلغ حوالي 99.97% ووقت معالجة يبلغ 5 ملي ثانية/الخطوة. يوضح هذا أن نموذج THL BP-3C هو النموذج الصحيح للتنبؤ بأسعار العملات المشفرة.

BAB I

PENDAHULUAN

1.1 Latar belakang

Kripto adalah salah satu jenis valuta modern yang dapat dipergunakan sebagai media pertukaran atau valuta yang diperdagangkan dan diproduksi melalui proses kriptografi. Mayoritas mata uang tersebut didistribusikan pada jaringan komputer berbasis teknologi *blockchain* yang tidak bergantung pada sistem perbankan pada umumnya.

Cryptocurrency telah ada selama sekitar satu dekade dan kini menjadi hal yang tidak asing lagi karena perkembangannya yang tersebar luas di seluruh dunia. *Cryptocurrency* merupakan valuta terbaru dengan proses transaksinya dilakukan secara online yang dirancang berdasarkan kriptografi dan tidak sama dengan seperti mata uang pada umumnya. Salah satunya adalah bitcoin. Karakteristik unik dari mata uang tersebut terletak pada fluktuasi harga hariannya yang dapat berubah setiap hari. Nilai tukar bitcoin ke US dollar pada 10 Agustus 2020 adalah 10.000 USD di pasar saham *yahoo finance* (Li & Wang, 2017).

Penggunaan *cryptocurrency* dimulai pada tahun 2009. Pada saat itu koin pertama yang ditemukan adalah bitcoin oleh Nakamoto dengan harga tertinggi sekitar 1151 USD/koin pada satu dekade terakhir (Farell, 2015). Hal ini diikuti oleh *cryptocurrency* lainnya salah satunya adalah *Ethereum* yang selanjutnya disebut dengan ETH. Sampai saat ini perkembangan naik secara signifikan yang ditandai oleh munculnya ribuan jenis koin dengan harga dan mekanisme yang berbeda. Kapitalisasi pasar seluruh *cryptocurrency* pada tahun 2016 berada pada nilai sekitar 1,6 miliar US dollar sampai dengan 1,7 miliar dolar pada tahun 2017 (Aggarwal & Kumar, 2021).

Bitcoin (BTC) merupakan salah satu *cryptocurrency* yang paling sering digunakan bertransaksi di Amerika Serikat dan Jepang. Namun, di Indonesia perkembangannya tidak begitu pesat yang disebabkan oleh belum adanya regulasi

dari pihak berwenang sehingga perkembangannya terjadi masif. Hal ini ditandai dengan peningkatan dari jumlah pedagang koin tersebut pada tahun 2022 terakhir. Di sisi lain transaksi yang dilakukan melalui teknologi *blockchain* berisiko tinggi namun dapat memberikan *passive income* yang menjajikan. Selanjutnya, jumlah BTC yang tersebar saat ini secara global berjumlah 17 juta koin, sedangkan algoritma yang dirancang hanya mampu menghasilkan 21 juta bitcoin dan diperkirakan akan habis pada tahun 2041 (Nakamoto, 2013).

Sifat *cryptocurrency* cenderung tidaklah menentu dan dapat dipengaruhi oleh berbagai aspek, terutama faktor permintaan dan penawaran. Berbeda dengan valuta secara umum yang dipengaruhi oleh kebijakan perbankan. Hal ini dapat diartikan bahwa salah satu aspek yang mempengaruhi harga *cryptocurrency* adalah transaksi yang dilakukan oleh para pedagang atau pemiliknya masing-masing. Selanjutnya, jumlah pedagang *cryptocurrency* di Indonesia pada akhir 2021 mencapai 4,2 juta orang yang tercatat di BEI dengan 2 juta SID aktif (Fageh & Iman, 2021).

Kemudian, kesenjangan yang menjadi dasar penelitian ini adalah bahwa para pedagang menghadapi tantangan transaksional sebagai akibat dari harga *cryptocurrency* yang berfluktuasi. Karena harga *cryptocurrency* sering kali dipengaruhi oleh dinamika penawaran dan permintaan atau oleh pedagang individu, fluktuasi harga ini membawa risiko lebih besar dibandingkan fluktuasi harga saham atau mata uang secara umum. Selain itu, harga *cryptocurrency* dapat berfluktuasi dengan cepat setiap menit, jam, atau detik, bergantung pada pedagang yang melakukan transaksi. Tentu saja, pedagang bitcoin menganggap hal ini sangat kontroversial, terutama ketika berinvestasi karena akan menghasilkan tingkat kegagalan yang tinggi. Selanjutnya untuk mengatasi hal tersebut, teknik prediksi dapat digunakan sebagai alternatif estimasi harga *cryptocurrency* sehingga dapat meminimalisir kegagalan yang mungkin dialami oleh trader terkait.

Selanjutnya, setiap orang memiliki hak untuk menggunakan barang dan memilih barang untuk diperdagangkan oleh orang tersebut. Kaitannya dengan

transaksi yang dilakukan oleh para *trader cryptocurrency* dijelaskan dalam QS An-Nisa ' ayat 29 sebagai berikut:

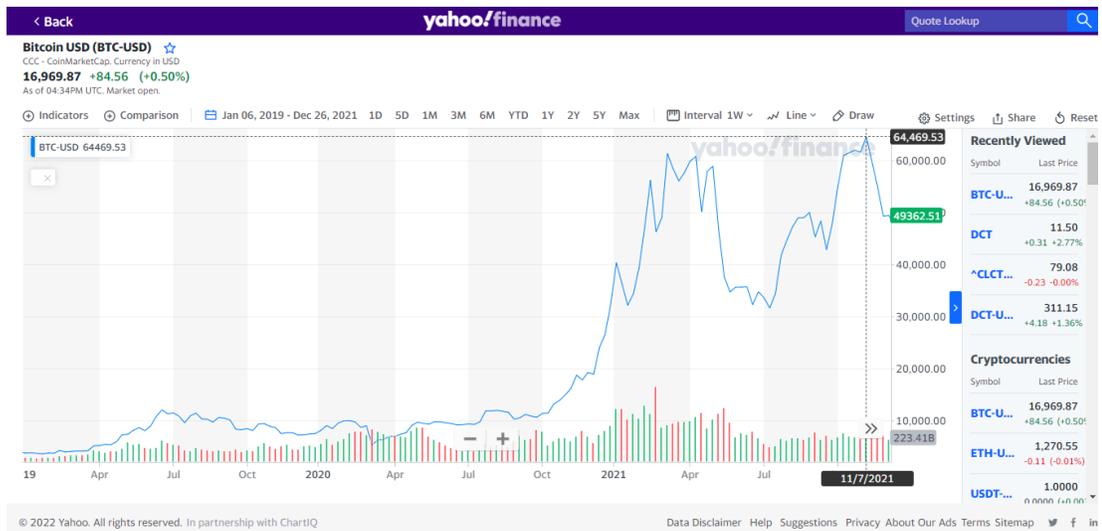
يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ ۗ وَلَا تَقْتُلُوا
 أَنْفُسَكُمْ ۗ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

Artinya: “Wahai orang-orang yang beriman! Janganlah kamu saling memakan harta sesamamu dengan jalan yang batil (tidak benar), kecuali dalam perdagangan yang berlaku atas dasar suka sama suka di antara kamu. Dan janganlah kamu membunuh dirimu. Sungguh, Allah Maha Penyayang kepadamu”. An- Nisa [4]:29.

Ayat tersebut secara jelas menjelaskan terkait dengan menjadi pedangan diperbolehkan atas asas saling menguntungkan satu sama lain. Selain itu, ayat tersebut menjelaskan tentang jual beli yang diperbolehkan untuk mencari harga sebagai bekal menjalani ibadah. Hal ini berkaitan dengan pengambilan keputusan yang dilakukan pada saat melakukan transaksi jual beli *cryptocurrency* dengan cara memprediksinya. Hal ini menjadi bagian penting saat mengambil keputusan pada saat melakukan transaksi karena berdampak langsung dengan hasil yang akan didapatkan oleh pelaku transaksi tersebut berdasarkan analisis history datanya (Setyaningsih, 2015).

Selanjutnya, metode yang dapat digunakan untuk memprediksi *cryptocurrency* tergolong banyak. Salah satunya adalah metode *deep learning* untuk melakukan prediksi lebih mendalam. Cara ini dapat dijalankan dengan menggunakan data masukan untuk mempelajari terlebih dahulu berbagai pola yang terbentuk akibat perubahan harga secara lebih mendalam. Selanjutnya algoritma ini menghasilkan output berupa perkiraan harga yang diperoleh dari variabel input dan output yang saling terhubung.

Permasalahan pada salah satu harga *cryptocurrency* yaitu BTC periode 2019 hingga 2021 yang naik drastis. Sedangkan pada periode tahun 2021 hingga 2023, harga nya menurun drastis yang dapat di lihat pada Gambar 1.1.



Gambar 1.1 Data deret waktu Bitcoin dari tahun 2019 hingga 2021
 Sumber: <https://finance.yahoo.com>

Selanjutnya, beberapa model dapat digunakan untuk memprediksi suatu harga seperti algoritma genetika, logika fuzzy, *artificial intelegent*, dan ANN. Konsep dari model ANN ditemukan dengan mengadopsi cara kerja sel syaraf pada otak manusia yang sampai saat ini terbukti efektif untuk memprediksi dengan menggunakan inputan data *time series* (Wijaya *et al.* 2010). Kelebihan dari model ANN adalah model tersebut dapat memproses kelompok data yang tidak terlihat dan tidak diperlukan (Wijaya *et al.* 2010). Sedangkan, kekurangannya terletak pada penentuan ketepatan jumlah layer dan jumlah node dengan proses kerja yang cenderung lama (Mulyo, 2016).

Kemudian pada penelitian sebelumnya yang menerapkan teknik prediksi untuk memperkirakan harga BTC dilakukan dengan menginvestigasi beberapa model, salah satunya adalah model ANN untuk mengetahui tingkat kinerja atau performance dengan menggunakan data harga Bitcoin untuk 2018. Sintesis penelitian ini menunjukkan bahwa ANN merupakan model terbaik dengan tingkat akurasi sekitar 92,15% (Serafini *dkk.* 2020, Othman *dkk.* 2020).

Berdasarkan uraian di atas, penelitian ini menyoroti kinerja algoritma *deep learning* berbasis model ANN dalam memprediksi harga *cryptocurrency*, khususnya harga BTC masa depan dari data harga *cryptocurrency* secara efektif dan optimal untuk mengetahui nilai kinerja atau performa terbaik dari model tersebut. Penelitian ini diharapkan dapat membantu para pedagang *cryptocurrency* atau mereka yang melakukan investasi *cryptocurrency* terkait dengan pengambilan keputusan dengan memberikan perkiraan harga *cryptocurrency* di masa depan.

1.2 Pernyataan masalah

1. Bagaimana pengaruh atribut data terhadap prediksi harga *cryptocurrency* berdasarkan model ANN?
2. Strategi apa yang paling optimal untuk memprediksi harga *cryptocurrency* berdasarkan model ANN?

1.3 Tujuan penelitian

1. Menganalisis atribut data yang mempengaruhi prediksi harga *cryptocurrency* berdasarkan model ANN.
2. Evaluasi kinerja model dalam memprediksi harga *cryptocurrency* berdasarkan model ANN.

1.4 Batasan masalah

1. Variabel input yang digunakan antara lain atribut *Date* harga *Open*, *High*, *Low*, *Close*, *Adj Close*, dan *Volume* dari BTC.
2. Variabel keluaran yang diharapkan adalah harga *Close* BTC.
3. Data harga Bitcoin harian periode 29 November 2021 – 19 Maret 2023 diambil dari yahoo finance.

1.5 Manfaat Penelitian

Prediksi harga *cryptocurrency* berdasarkan model ANN diharapkan dapat memberikan manfaat bagi para pedagang atau investor dalam mengambil keputusan investasi. Serta di bidang teknologi untuk berkontribusi dalam mengusulkan model terbaik mengenai peramalan harga *cryptocurrency*.

BAB II

STUDI PUSTAKA

2.1 **Prediksi harga *cryptocurrency* berdasarkan model ANN**

Studi prediksi harga *cryptocurrency* berbasis *Neural Network* (NN) saat ini terus berkembang. Secara empiris Radityo *dkk.* (2017) menyelidiki pemodelan dan prediksi harga bitcoin dengan menganalisis deret waktu pemrosesan berbasis NN dengan membandingkan beberapa model seperti *Backpropagation Neural Network* (BPNN), *Genetic Algorithm Backpropagation Neural Network* (GABPNN), *Genetic Algorithm Neural Network* (GANN), *Neuron Evolution of Augmenting Topologies* (NEAT) untuk mengungkap efek model berbasis NN dan menetapkan harga terbaru berdasarkan informasi blockchain. Pengusulan model dalam studi ini menunjukkan performa terbaiknya dalam memprediksi time series harga bitcoin dengan nilai error untuk setiap model secara berurutan sekitar 0.038, 0.49, 0.066, dan 0.097 *Mean Absolute Percentage Error* (MAPE) serta dapat menjelaskan tingginya volatilitas harga bitcoin saat ini. Meskipun model ini dapat menjelaskan deret waktu harga bitcoin dengan baik, variabilitasnya harus dimodelkan dan diprediksi dengan lebih tepat. Hal ini dapat dicapai dengan mengadopsi metode dari *machine learning* lain atau mempertimbangkan kemampuan masukan baru terkait variabilitas bitcoin.

Selain itu, Yiyang & Yeze (2019) mengeksplorasi teknik *machine learning* model ANN dan LSTM untuk menganalisis dinamika harga tiga *cryptocurrency* yaitu bitcoin, ethereum, dan ripple. Temuan eksplorasi ini menunjukkan bahwa model ANN lebih mengandalkan *time frame* yang cenderung lebih panjang dan sebaliknya untuk model LSTM. Namun tingkat akurasi kedua model cenderung sama. Hal ini menunjukkan bahwa harga *cryptocurrency* pada penelitian ini dapat diprediksi dengan baik. Meskipun demikian, hasil yang diharapkan dapat bervariasi bergantung pada penggunaan model pembelajaran mesin yang terlibat.

Selanjutnya, studi oleh de Souza *dkk.* (2019) menyelidiki kinerja teknik *machine learning* dalam prediksi harga *cryptocurrency* menggunakan model SVM dan ANN. Tujuan utama dari penelitian ini adalah untuk menyimpulkan penerapan pembelajaran mesin terhadap harga historis Bitcoin dibandingkan dengan harga emas dan perak. Temuan penelitian ini menunjukkan bahwa model SVM memiliki performa lebih efektif dibandingkan dengan model ANN yang memperoleh nilai akurasi sekitar 57.41% dibandingkan model ANN dengan nilai akurasi sekitar 56.26%.

Kemudian Gopal & Senthilkumar (2020) melakukan penelitian prediksi harga bitcoin dengan pendekatan model BPNN. Mereka menerapkan algoritma *backpropagation* untuk memperbaiki hal-hal yang diperlukan dengan menggunakan dua *hidden layer* antara lain perhitungan *feed-forward*, *backpropagation* pada lapisan keluaran, dan pembaruan bobot yang diukur dengan *Mean Square Error* (MSE). Temuan penelitian ini menunjukkan bahwa nilai akurasi jaringan pada tahap validasi dan pengujian sebesar 0,86048 dan 0,94521 dengan nilai error yang cukup kecil yaitu sekitar 0,00039 MSE. Hal ini dapat memvalidasi bahwa ANN adalah model yang paling cocok untuk memprediksi tren harga bitcoin. Nantinya, hal ini dapat diverifikasi lebih lanjut menggunakan *cryptocurrency* lainnya.

Secara umum informasi merupakan salah satu faktor pendorong pergerakan volatilitas harga aset di pasar keuangan, baik secara simetris maupun asimetris (Othman *et al.* 2020). Mereka menyoroti dan menyelidiki struktur volatilitas serta karakteristik *cryptocurrency* sebagai aset investasi atau sebagai mata uang digital melalui studi harga bitcoin. prediksi dengan model ANN volatilitas simetrisnya. Temuan dari studi ini menunjukkan bahwa ANN merupakan model yang efektif dan memadai untuk memprediksi harga Bitcoin dengan tingkat akurasi sekitar 92.15% dari harga sebenarnya. Namun, volatilitas di dalamnya tidak informatif secara asimetris. Oleh karena itu, atribut lain perlu digunakan pada penelitian selanjutnya.

Safari & Ghavifekr (2021) melakukan penelitian mengenai prediksi indeks harga saham internasional amazon yang biasanya lebih dikenal dengan AMZN dengan mengimplementasikan pemrograman python menggunakan model ANN. Penelitian ini mewakili salah satu program yaitu konsol python yang diatur berdasarkan model NN dan *Artificial Intelligence* (AI) untuk memprediksi harga *cryptocurrency* di masa depan secara berkualitas yang berupaya memperoleh akurasi tinggi atau mendekati aslinya. Temuan dari penelitian ini menunjukkan bahwa program yang dilaksanakan dalam penelitian ini dapat berkinerja secara efektif untuk memprediksi harga saham. Secara berurutan eksperimen yang dilakukan cenderung lebih efektif kemampuan prediksinya dibandingkan dengan metode klasik. Hal ini ditandai dengan tujuh aspek inovasi dalam studinya, salah satunya adalah penggabungan model AI dengan NN pada sistem konsol python untuk memprediksi harga BTC dan ETH di masa depan. Hal inilah yang mendasari penulis menggunakan bahasa program python dalam menerapkan model ANN pada penelitian yang akan dilakukan.

Selanjutnya, Cavalli & Amoretti (2021) mengusulkan model melalui penghitungan data di media sosial untuk membangun kumpulan data yang berguna, khususnya dalam aspek perdagangan *cryptocurrency*. Strategi perdagangan berdasarkan model *One-Dimensional Convolutional Neural Network* (1D CNN) diperkenalkan dan disimulasikan untuk memprediksi harga *cryptocurrency* terutama harga bitcoin. Selengkapnya, mereka membandingkan model 1D-CNN dengan model *Long-short Term Memory* (LSTM). Temuan penelitian ini menunjukkan bahwa model 1D-CNN mampu bekerja dengan akurasi lebih tinggi sekitar 74.24% dibandingkan model LSTM yang memperoleh nilai akurasi sekitar 54.31% dalam memprediksi tren harga Bitcoin. Selain itu penerapan model 1D-CNN dapat meningkatkan keuntungan saat tren harga Bitcoin sedang bullish dan dapat mengurangi kerugian saat tren harga Bitcoin sedang bearish. Namun nilai akurasi model yang diperoleh dari pelatihan model pembelajaran mesin cenderung fiktif. Hal

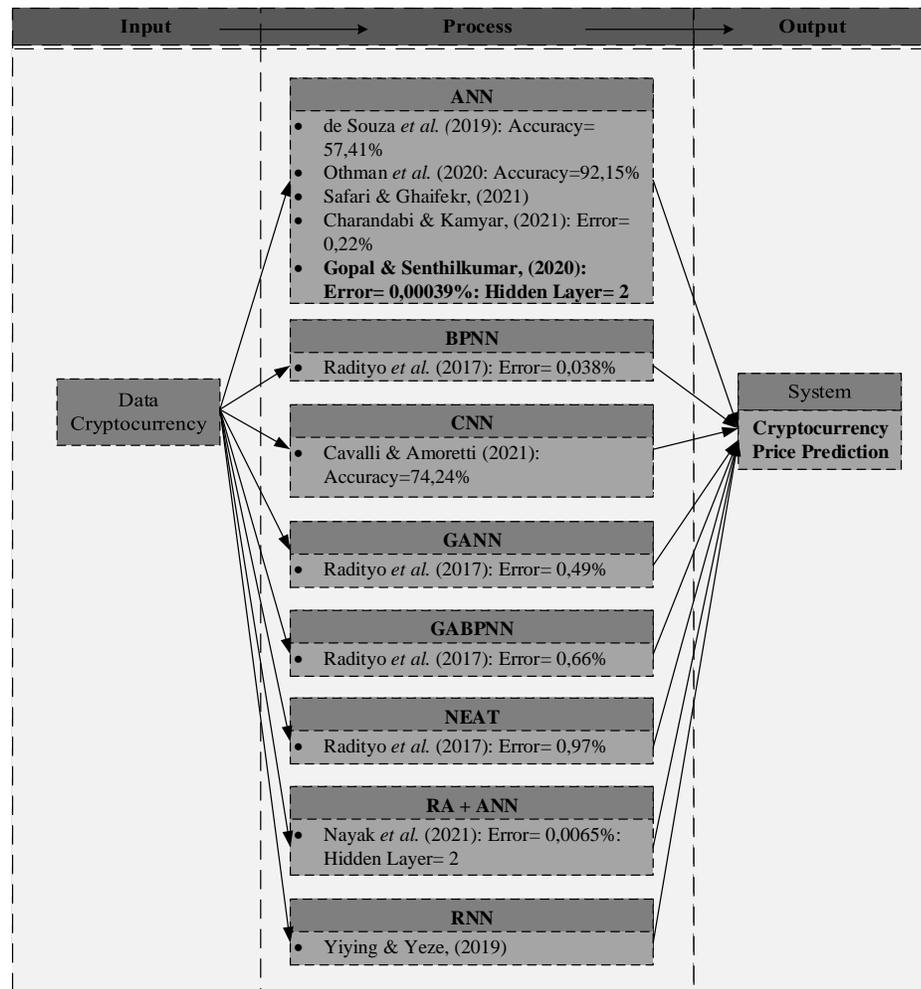
ini dikarenakan sistem yang digunakan untuk melatih model dijalankan secara manual.

Secara faktual, penelitian mengenai *cryptocurrency* berdasarkan model ANN sejauh ini cenderung berkembang. Charandabi & Kamyar (2021) menyelidiki sifat baru literatur untuk menyajikan dan membandingkan beberapa makalah penelitian sebelumnya dengan mengadopsi beberapa pendekatan berbasis model ANN dalam memprediksi harga *cryptocurrency*. Temuan penelitian ini menunjukkan bahwa nilai MAPE yang dihasilkan dari setiap bagian model ANN berbasis pendekatan MAPE 0.22%. Hal ini dapat diartikan bahwa model dapat bekerja secara efektif. Pekerjaan berikutnya yang mungkin dilakukan para peneliti adalah fokus hanya pada penerapan data dari *cryptocurrency* yang tidak terlalu fluktuatif, misalnya Ethereum , XRP, dll.

Selain itu, efektivitas prediksi *cryptocurrency* merupakan bidang penelitian yang cenderung populer di kalangan peneliti. Nayak *dkk.* (2021) mengusulkan model untuk memprediksi harga penutupan *cryptocurrency* berbasis ANN berdasarkan algoritma Rao dengan menerapkan dua *hidden layer* menggunakan enam *cryptocurrency* seperti Bitcoin, Litecoin, Ethereum, CMC 200, Tether, dan Ripple. Temuan penelitian ini menunjukkan bahwa model yang diusulkan yaitu hybrid ANN melalui algoritma Rao (RA+ANN) dapat bekerja secara efektif dengan nilai MAPE dan ARV terendah sekitar 0.0065% MAPE dan 0.0055% ARV pada mata uang Tether.

2.2 Kerangka teoritis

Bagian ini membahas teori pendukung terkait prediksi harga *cryptocurrency* untuk menentukan parameter dan variabel sebagai data masukan dan menyelidiki penggunaan beberapa pendekatan berbasis model ANN yang digunakan sebagai acuan dari keluaran kerangka teori. Kerangka teoritis untuk prediksi harga *cryptocurrency* diberikan pada Gambar 2.1.



Gambar 2.1 Kerangka teoritis prediksi harga *cryptocurrency*

(Sumber: diolah peneliti)

Parameter yang digunakan dalam algoritma *machine learning* berperan penting dalam membangun model yang baik. Parameter mempengaruhi cara kerja algoritma, seperti toleransi kesalahan, jumlah iterasi, atau berbagai opsi lainnya. Oleh karena itu, perlu juga memperhatikan kombinasi parameter yang dapat digunakan untuk memilih algoritma pembelajaran mesin yang baik.

Untuk mendapatkan pendekatan model yang akan diusulkan, penulis melakukan studi literatur dengan mencari makalah terkait prediksi harga *cryptocurrency* berbasis model ANN. Kemudian penulis mereview beberapa makalah

untuk mendapatkan nilai akurasi, presisi, recall, dan error dari beberapa strategi berbasis model ANN. Penulis mengungkap kinerja masing-masing pendekatan berdasarkan model ANN dengan mengurutkan ukuran kinerja untuk merancang strategi yang digunakan sebagai dasar penelitian yang akan dilakukan seperti terlihat pada Tabel 2.1.

Tabel 2.1 Performa prediksi harga *cryptocurrency* berbasis model ANN

No	Model	Penulis	Nilai error	Akurasi	Hidden layer
1	ANN	de Souza <i>et al.</i> 2019	-	57,41%	-
		Othman <i>et al.</i> 2020	-	92,15%	-
		Gopal & Senthilkumar (2020)	0,00039%	-	2
		Safari & Ghavifekr (2021)	-	-	-
		Charandabi & Kamyar (2021)	0,22%	-	-
2	BPNN	Radityo <i>et al.</i> (2017)	0,038%	-	-
3	CNN	Cavalli & Amoretti (2021)	-	74,24%	-
4	GANN	Radityo <i>et al.</i> (2017)	0,49%	-	-
5	GABPNN	Radityo <i>et al.</i> (2017)	0,066%	-	-
6	NEAT	Radityo <i>et al.</i> (2017)	0,097%	-	-
7	RA + ANN	Nayak <i>et al.</i> (2021)	0,0065%	-	2
8	RNN	Yiyang & Yeze (2019)	-	-	-

Tabel 2.1 menunjukkan kinerja prediksi harga *cryptocurrency* yang dieksplorasi dan diukur menggunakan berbagai pendekatan berdasarkan model ANN dalam memprediksi harga *cryptocurrency* oleh para peneliti. Data yang digunakan dari masing-masing penelitian yaitu bertipe numerik sebagai fitur atau variabel utama dalam memprediksi harga *cryptocurrency*.

Dalam hal ini Radityo *dkk.* (2017) menyelidiki pemodelan dan prediksi harga *cryptocurrency* dengan menganalisis time series dan membandingkan beberapa strategi pada model berbasis ANN dan memperoleh hasil kinerja yang efektif pada strategi BPNN dengan nilai error sekitar 0,038 MAPE. Sedangkan Gopal & Senthilkumar (2020) memperoleh nilai error sekitar 0,00039% dari penerapan strategi ANN dengan dua *hidden layer* melalui empat tahapan yang telah disebutkan sebelumnya. Temuan ini dapat diverifikasi lebih lanjut dengan menggunakan beberapa *cryptocurrency*.

Selanjutnya penggunaan strategi seperti CNN, GANN, GABPNN, NEAT, RA + ANN dengan dua *hidden layer*, dan RNN berbasis NN (Cavalli & Amoretti, 2021; Nayak et al., 2021; Radityo et al., 2017; Yiyang & Yeze, 2019) terus berkembang dalam eksplorasi. Secara keseluruhan eksplorasi mereka menunjukkan hasil yang cenderung sama, dimana penerapan beberapa strategi berbasis NN dapat memprediksi harga *cryptocurrency* dengan baik dengan nilai error sekitar 0.0065% - 0.49% dan nilai akurasi sekitar 74.24% - 92.15%.

Di sisi lain, Othman *dkk.* (2020) memprediksi harga Bitcoin berdasarkan struktur volatilitas simetrisnya menggunakan model ANN dan memperoleh nilai akurasi sekitar 92,15%. Hal ini menunjukkan bahwa model ANN dapat bekerja secara efektif. Berbeda dengan temuan de Souza et al. (2019), model yang mereka usulkan tidak dapat berjalan efektif dengan nilai akurasi sekitar 57,41%. Hal ini disebabkan oleh besarnya variasi volatilitas jika diukur dalam jangka pendek. Oleh karena itu, mereka merekomendasikan penerapan strategi *backpropagation* berbasis jaringan saraf dalam penelitian masa depan. Hal ini diperkuat dengan temuan Gopal & Senthilkumar (2020) yang dapat dijadikan dasar penerapan ANN pada penelitian selanjutnya.

Berdasarkan uraian tersebut terlihat bahwa model ANN dengan dua *hidden layer* menunjukkan tingkat kinerja terbaik dan dapat bekerja secara efektif dengan nilai error sekitar 0.00039% (Gopal & Senthilkumar, 2020). Menurut Muhammad *dkk.* (2022), optimalisasi akurasi pengukuran dan kinerja algoritma penting untuk menyelesaikan masalah terkait prediksi, dalam hal ini harga *cryptocurrency*. Oleh karena itu, dalam penelitian ini, penulis menyoroti kinerja model ANN dalam memprediksi harga *cryptocurrency* di masa depan.

BAB III

DESAIN PENELITIAN

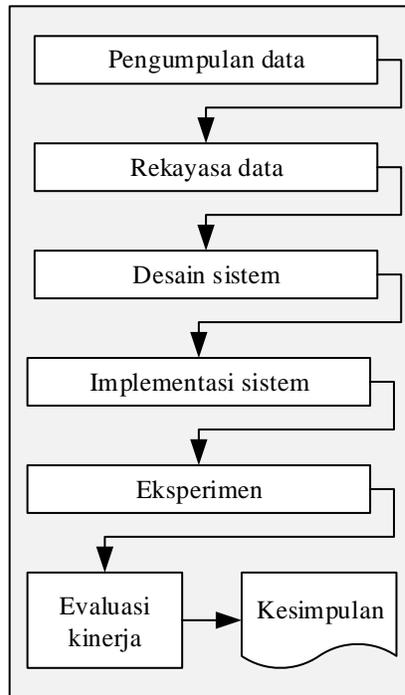
Desain penelitian adalah rancangan sistematis yang memberikan gambaran, garis besar, dan rincian prosedur penelitian bagi peneliti mulai dari perumusan masalah hingga analisis metode. Asenahabi (2019) menjelaskan bahwa desain penelitian adalah suatu rencana yang dirancang oleh peneliti dalam melakukan penelitian. Di sisi lain, Sileyew (2019) menyatakan bahwa desain penelitian merupakan persiapan peneliti yang bertujuan untuk memperoleh pemahaman terhadap beberapa kelompok atau fenomena dalam setting alamiahnya. Selain itu, desain penelitian dapat memberikan tanggung jawab terhadap seluruh langkah yang akan diambil peneliti (Margono, 2005).

Penelitian ini menggunakan pendekatan kuantitatif karena secara keseluruhan penulis menggunakan data numerik yang dianalisis menggunakan analisis statistika dengan persamaan MSE (Lim *et al.* 2016). Secara umum analisis isi kuantitatif merupakan suatu teknik penelitian ilmiah yang bertujuan untuk mengetahui ciri-ciri dan menarik kenodean dari suatu isi. Selain itu, analisis ini dimaksudkan untuk mengidentifikasi secara sistematis komunikasi-komunikasi yang muncul yang dilakukan dengan cara yang objektif, valid, andal, dan dapat ditiru (Rourke *et al.* 2001).

3.1 **Prosedur penelitian**

Prosedur penelitian merupakan langkah-langkah yang dilakukan peneliti untuk mengumpulkan data dan menjawab berbagai pertanyaan penelitian. Dalam penelitian ini penulis membahas terkait teknik pengumpulan data, langkah-langkah pengembangan sistem, dan eksperimen. Penelitian eksperimen menggunakan data dalam penelitian dan dapat menghasilkan kenodean yang dapat dibuktikan dengan eksperimen atau observasi.

Penelitian ini termasuk penelitian eksperimental dengan menggunakan data *cryptocurrency*. Prosedur penelitian dapat dilihat pada Gambar 3.1.



Gambar 3.1 Prosedur penelitian
(Sumber: diolah peneliti)

3.1.1 Pengumpulan data

Pengumpulan data merupakan proses utama di hampir setiap jenis penelitian. Kualitas data yang buruk akan mempengaruhi validitas suatu penelitian yang kemudian mengakibatkan hasil yang lemah (Tan, 2006). Tahapan ini dilakukan untuk mengumpulkan data-data yang diperlukan untuk penelitian ini. Jenis data yang digunakan dalam penelitian ini adalah data sekunder yang bersumber dari situs yahoo finance. Pengumpulan data yang dilakukan pada penelitian ini adalah dengan mengunduh data time series harga BTC dari situs <https://finance.yahoo.com/crypto/> periode 29 November 2021 – 19 Maret 2023. Pengumpulan data dilakukan pada tanggal 20 Maret 2023. Atribut yang didapat antara lain *Date*, *Open*, *High*, *Low*, *Close*, *Adj Close*, dan *Volume*. Data yang

diperoleh dari yahoo finance berjumlah 476 data untuk setiap atribut. BTC memiliki kelebihan antara lain pemrosesan transaksi dilakukan secara online tanpa melibatkan pihak ketiga, teknik kriptografi), dan hanya dikendalikan oleh pemiliknya (Ausop & Aulia, 2018). Data harga BTC tersebut disajikan pada Tabel 3.1.

Tabel 3.1 Data harga bitcoin

No.	Open	High	Low	Close	Adj Close	Volume
1	57291.90625	58872.87891	56792.52734	57806.56641	57806.56641	32370840356
2	57830.11328	59113.40234	56057.28125	57005.42578	57005.42578	36708594618
3	56907.96484	59041.68359	56553.08203	57229.82813	57229.82813	36858195307
4	57217.37109	57349.23438	55895.13281	56477.81641	56477.81641	32379968686
5	56509.16406	57482.16797	52496.58594	53598.24609	53598.24609	39789134215
6	53727.87891	53904.67969	42874.61719	49200.70313	49200.70313	61385677469
7	49201.51953	49768.14844	47857.49609	49368.84766	49368.84766	37198201161
8	49413.48047	50929.51953	47281.03516	50582.625	50582.625	37707308001
9	50581.82813	51934.78125	50175.80859	50700.08594	50700.08594	33676814852
10	50667.64844	51171.375	48765.98828	50504.79688	50504.79688	28479699446
11	50450.08203	50797.16406	47358.35156	47672.12109	47672.12109	29603577251
12	47642.14453	50015.25391	47023.69922	47243.30469	47243.30469	30966005122
13	47264.63281	49458.21094	46942.34766	49362.50781	49362.50781	25775869261
14	49354.85547	50724.86719	48725.85156	50098.33594	50098.33594	21939223599
15	50114.74219	50205	45894.84766	46737.48047	46737.48047	32166727776
16	46709.82422	48431.39844	46424.49609	46612.63281	46612.63281	34638619079
17	48379.75391	49473.95703	46671.96484	48896.72266	48896.72266	36541828520
18	48900.46484	49425.57422	47529.87891	47665.42578	47665.42578	27268150947
19	47653.73047	48004.89453	45618.21484	46202.14453	46202.14453	32902725329

476	26969.50391	28440.56055	26907.7168	28038.67578	28038.67578	37769448859

Catatan: atribut *date* dihapus

3.1.2 Rekayasa data

Pada tahap ini penulis melakukan pengolahan data atau pembersihan data dengan format yang disesuaikan dengan kebutuhan penelitian. Hal ini bertujuan untuk menghasilkan nilai akurasi yang lebih tepat dan menghindari overfitting pada saat proses prediksi menggunakan teknik *min-max scale*. Hasil dari normalisasi data pada proses ini disajikan pada Tabel 3.2.

Tabel 3.2 Hasil normalisasi data

No.	Date	Open	High	Low	Close	Adj Close	Volume
1	2021-11-29	0.9872	0.994388	1	1	1	0.221572
2	2021-11-30	1	1	0.982151	0.980934	0.980934	0.260554
3	2021-12-01	0.978069	0.998327	0.994187	0.986274	0.986274	0.261898
4	2021-12-02	0.985427	0.958839	0.978215	0.968378	0.968378	0.221654
5	2021-12-03	0.968585	0.961941	0.895713	0.899848	0.899848	0.288237
6	2021-12-04	0.902439	0.878472	0.662133	0.795193	0.795193	0.482315
7	2021-12-05	0.794791	0.78196	0.783096	0.799194	0.799194	0.264954
8	2021-12-06	0.799832	0.809057	0.769102	0.82808	0.82808	0.269529
9	2021-12-07	0.827618	0.832511	0.839375	0.830876	0.830876	0.233309
10	2021-12-08	0.829659	0.8147	0.80515	0.826228	0.826228	0.186605
11	2021-12-09	0.824485	0.805969	0.770979	0.758814	0.758814	0.196704
12	2021-12-10	0.757705	0.787726	0.762855	0.748609	0.748609	0.208948
13	2021-12-11	0.748727	0.774729	0.76088	0.799043	0.799043	0.162307
14	2021-12-12	0.798438	0.804282	0.804176	0.816555	0.816555	0.127828
15	2021-12-13	0.81651	0.792153	0.735451	0.736571	0.736571	0.219738
16	2021-12-14	0.735532	0.750772	0.748309	0.7336	0.7336	0.241952
17	2021-12-15	0.775247	0.775096	0.754316	0.787958	0.787958	0.259055
18	2021-12-16	0.787631	0.773968	0.775143	0.758655	0.758655	0.175717
19	2021-12-17	0.757981	0.740821	0.728736	0.723831	0.723831	0.226352
...
476	2023-03-19	26969.5	28440.6	26907.7	28038.7	28038.7	37769448859

Setelah data dinormalisasi, selanjutnya penulis melakukan pembagian data yang bertujuan untuk membedakan antara data yang digunakan untuk proses pelatihan dan data yang digunakan untuk proses pengujian. Tahapan pendistribusian data dibagi menjadi dua kategori yaitu data pelatihan dan data pengujian.

Distribusi data untuk model prediksi yang dibangun dibagi sekitar 80% atau 381 dari total data yang akan digunakan sebagai data pelatihan dan 20% atau 95 data sebagai data pengujian. Pendistribusian data dilakukan berdasarkan hasil eksperimen dengan mempertimbangkan pembagian data yang berkemungkinan besar dapat memperoleh nilai performa atau kinerja terbaik pada saat pengujian model yang diusulkan dalam penelitian.

3.1.3 Desain sistem

Perancangan sistem akan menjelaskan bagaimana sistem memprediksi harga *cryptocurrency* berdasarkan model ANN. Alur proses *design system* dalam penelitian ini disajikan pada Gambar 3.2.



Gambar 3.2 Desain sistem

(Sumber: diolah peneliti)

A. Data harga *cryptocurrency*

Pada tahap awal, data harga *cryptocurrency* akan diproses di sistem. Data masukan yang diolah pada tahap ini berupa data mentah dengan format *comma separated values* (CSV) yang terdiri dari atribut sebagai berikut:

Tabel 3.3 Detail data harga *cryptocurrency*

No	Atribut	Rentang nilai	Tipe data	Satuan
1	<i>Date</i>	-	<i>Datetime</i>	-
2	<i>Open</i>	15782 - 57830	<i>Numeric</i>	USD
3	<i>High</i>	16253 - 59113	<i>Numeric</i>	USD
4	<i>Low</i>	15599 - 56792	<i>Numeric</i>	USD
5	<i>Close</i>	15787 - 57806	<i>Numeric</i>	USD
6	<i>Adj Close</i>	15787 - 57806	<i>Numeric</i>	USD
7	<i>Volume</i>	130 - 118992465607	<i>Numeric</i>	USD

Berdasarkan Tabel 3.3 terdapat 7 atribut dengan frekuensi perubahan harga selama 1 hari sebagai data input dalam prediksi yang dilakukan oleh sistem diantaranya *Date*, *Open*, *High*, *Low*, *Close*, *Adj Close*, dan *Volume*. *Date* merupakan salah satu atribut data harga *cryptocurrency* pada hari tersebut yang termasuk dalam tipe data *Datetime*. Kemudian *Open* adalah harga awal hari yang termasuk dalam tipe data numerik sama dengan atribut selanjutnya dengan rentang nilai antara 15782 – 57830 USD. Selanjutnya *High* merupakan harga tertinggi dengan kisaran nilai antara 16253 – 59113

USD. Lalu, *Low* merupakan harga terendah dengan kisaran nilai antara 15599 – 56792 USD. Selanjutnya *Close* merupakan harga terakhir yang kemudian menjadi harga awal di hari mendatang dengan kisaran nilai antara 15787 – 57806 USD. Sedangkan, *Adj Close* adalah harga penutupan yang disesuaikan dengan kisaran nilai antara 15787 – 57806 USD, dan *Volume* adalah total seluruh transaksi pada hari itu dengan kisaran nilai antara 130 – 118992465607 USD.

Informasi tersebut menunjukkan bahwa kisaran nilai setiap atribut berbeda secara signifikan, yaitu sekitar 5000 USD. Hal ini akan menyebabkan bertambahnya kesalahan pada sistem pada saat melakukan prediksi (Prasetyo, 2017). Oleh sebab itu, perlu dilakukan proses normalisasi data pada proses selanjutnya.

B. Preprocessing data

Pada tahap ini dilakukan normalisasi data untuk menghilangkan nilai null dengan menggunakan teknik min-max scaling pada dataset yang telah disiapkan guna meminimalisir kesalahan pada saat pengujian model prediktif. Perhitungan skala min-max dilakukan dengan rumus sebagai berikut:

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Di mana:

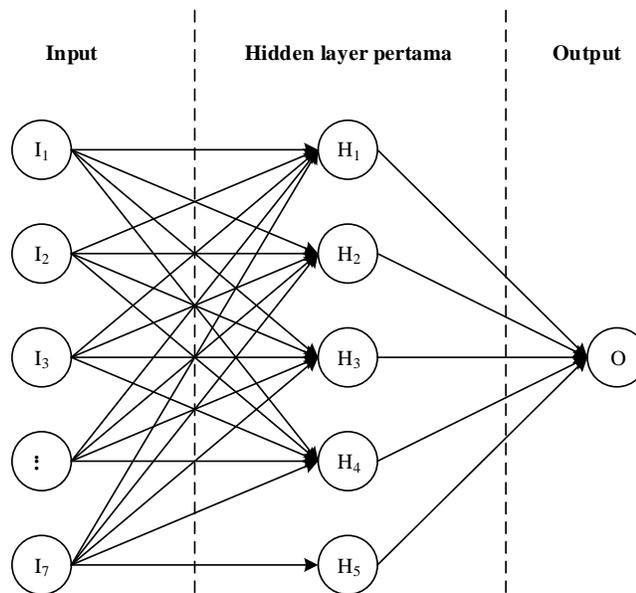
x = data yang dinormalisasi
 x_{norm} = data yang ternormalisasi
 $\min(x)$ = nilai terkecil dari keseluruhan data
 $\max(x)$ = nilai terbesar dari keseluruhan data

C. Model ANN

Pada model ANN, hal pertama yang dilakukan adalah menentukan variabel-variabel yang mempengaruhi perhitungan prediksi atau variabel prediktor pada dataset untuk menguji jaringan multi-layer dalam menjelaskan pengaruh variabel input. Menurut Setyawati (2002) dalam pemilihan variabel

masukan berpengaruh signifikan terhadap keakuratan prediksi jaringan saraf, seseorang dapat memperoleh hasil yang berbeda atau lebih baik jika telah dipelajari variabel masukan penting lainnya. Selanjutnya, data masukan distandarisasi untuk menghindari overfitting dan fungsi transfer digunakan untuk menghasilkan prediksi terbaik.

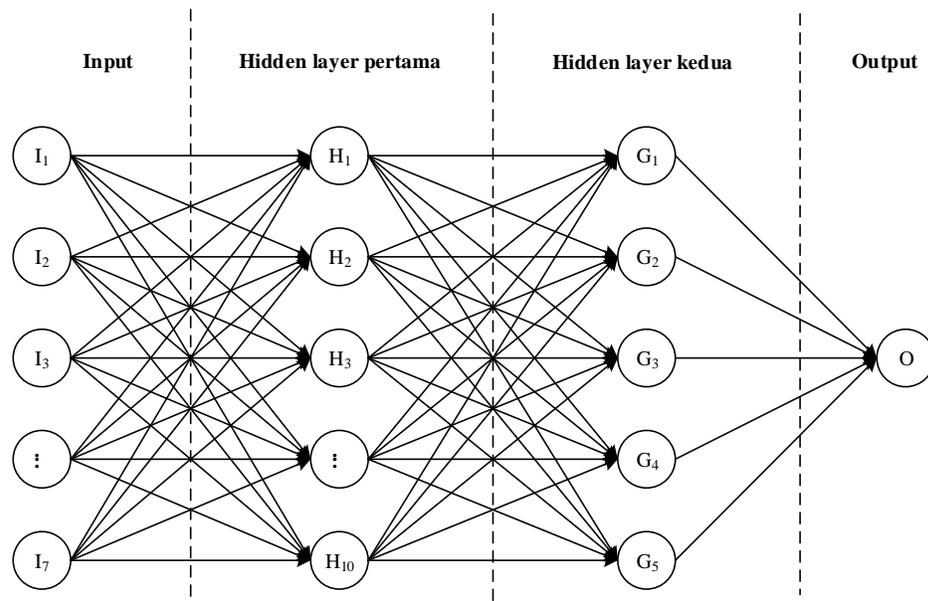
ANN memiliki arsitektur yang terdiri dari jumlah layer dan jumlah node pada setiap layer. Sedangkan untuk kasus *backpropagation* adalah dengan multilayer yang terdiri dari input, tersembunyi, dan output. Fausett, (1994) menyatakan bahwa 1 *hidden layer* sudah cukup untuk menghasilkan output yang memenuhi target. Oleh karena itu, arsitektur jaringan pertama yang dirancang pada penelitian ini menggunakan 3 lapisan NN dengan 7 node pada lapisan input, 5 node pada *hidden layer*, dan 1 node pada lapisan output. Arsitektur jaringan pertama dalam perancangan model ANN dapat dilihat pada Gambar 3.3.



Gambar 3.3 Arsitektur jaringan pertama model ANN
(Sumber : diolah peneliti)

Banyaknya node pada setiap lapisan dipilih karena 7 node pada *input layer* mewakili 7 atribut data masukan. Sedangkan 5 node pada *hidden layer* mewakili 5 digit angka harga untuk setiap atribut kecuali atribut *Volume (V)*, dan 1 node pada lapisan keluaran mewakili hasil kinerja prediksi harga *cryptocurrency*.

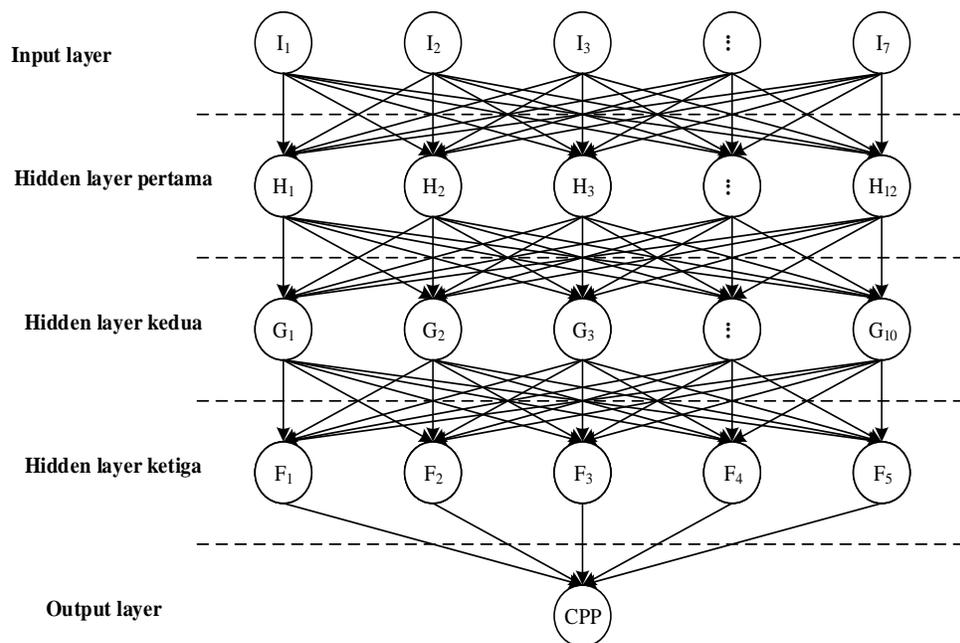
Sementara itu, Thomas *dkk.* (2017) menyatakan bahwa biasanya menggunakan dua *hidden layer* lebih baik daripada satu *hidden layer* untuk merancang jaringan ANN. Berdasarkan hal tersebut maka arsitektur jaringan kedua yang dirancang pada penelitian ini terdiri dari 4 layer NN dengan 7 node untuk lapisan input, 10 node untuk *hidden layer* pertama, 4 node untuk *hidden layer* kedua, dan 1 node untuk lapisan keluaran. Jumlah node pada tiap layer dipilih dengan alasan yang sama berdasarkan arsitektur jaringan pertama, hanya saja 10 node pada *hidden layer* pertama dipilih dengan cara mencari sedekat mungkin jumlah node dari *hidden layer* kedua, yaitu dengan cara mengalikannya dengan 2. Arsitektur jaringan kedua dalam perancangan model ANN dapat dilihat pada Gambar 3.4.



Gambar 3.4 Arsitektur jaringan kedua model ANN

(Sumber : diolah peneliti)

Selanjutnya, Xiao dkk. (2017) mengusulkan beberapa *hidden layer* dari *extreme machine learning algorithm*, menggunakan tiga *hidden layer* untuk menentukan kinerja model. Dengan demikian, arsitektur jaringan ketiga yang dirancang pada penelitian ini terdiri dari 5 layer NN dan menggunakan 3 *hidden layer* dengan 7 node untuk *input layer*, 12 node untuk *hidden layer* pertama, 10 node untuk *hidden layer* kedua, 5 node untuk *hidden layer* ketiga, dan 1 node untuk *output layer*, seperti yang dapat dilihat pada Gambar 3.5.



Gambar 3.5 Arsitektur jaringan ketiga model ANN

(Sumber : diolah peneliti)

Pemilihan jumlah node pada setiap lapisan dilakukan dengan alasan dasar sebagai berikut:

1. *Input layer*: Menggunakan 7 node karena menampung 7 atribut data.
2. *Hidden layer* pertama: menggunakan 12 node karena mewakili 12 digit rentang nilai pada atribut *Volume* (Tabel 3.3).
3. *Hidden layer* kedua: menggunakan 10 node yang dipilih dengan mencari sedekat mungkin node keluaran yang akan dihasilkan pada *hidden layer* ketiga, yaitu jumlah node *hidden layer* ketiga dikalikan 2.

4. *Hidden layer* ketiga: menggunakan 5 node karena mewakili 5 digit angka harga untuk setiap atribut kecuali atribut *Volume (V)*.
5. *Output layer*: lapisan ini menggunakan 1 node karena keluaran dari sistem ini adalah prediksi harga *cryptocurrency*.

Sedangkan variasi strategi ANN pada penelitian ini dibagi menjadi tiga bagian:

1. NN dengan 7 node untuk *input layer*, 5 node untuk *hidden layer* pertama, dan 1 node untuk lapisan keluaran (7-5-1).
2. NN dengan 7 node untuk *input layer*, 8 node untuk *hidden layer* pertama, 4 node untuk *hidden layer* kedua, dan 1 node untuk lapisan keluaran (7-10-5-1).
3. NN dengan 7 node untuk *input layer*, 12 node untuk *hidden layer* pertama, 10 node untuk *hidden layer* kedua, 5 node untuk *hidden layer* ketiga, dan 1 node untuk lapisan keluaran (7-12-10-5-1)

Untuk menentukan parameter yang digunakan pada penelitian ini meliputi learning rate, optimizer, dan fungsi aktivasi. Penentuan parameter tersebut akan mempengaruhi kinerja algoritma pada jaringan yang dirancang. Learning rate yang digunakan pada penelitian ini adalah 0.2, sedangkan optimizer yang digunakan adalah adam, dan untuk fungsi aktivasi yang dipilih adalah Rectified linear unit (ReLU) karena nilai keluaran yang diharapkan berada pada rentang antara 0 hingga minus (-).

Tahap propagasi maju dilakukan bertujuan untuk mengevaluasi kesesuaian model terbaik. Sedangkan, fase *backpropagation* bertujuan untuk menyesuaikan tingkat kesalahan pada model dengan mengoperasikan sistem secara terbalik. Kemudian, umpan balik dari proses tersebut akan memberikan bobot dan nilai akurasi baru pada lapisan utama neuron buatan. Pengulangan siklus dilakukan beberapa kali untuk membuat prediksi harga *cryptocurrency* akurat. Selanjutnya jaringan ditata ulang dengan bobot acak, dan dihitung

gradien fungsi error yang bertujuan untuk memperbaiki bobot asli dengan rumus sebagai berikut (Sivanandam & Paulraj, 2009):

$$net = w_0 + \sum_{i=1}^n x_i w_i \quad (2)$$

Di mana:

- net = nilai keluaran node yang sedang dihitung
- w_0 = berat bias node
- i = indeks yang digunakan dalam penjumlahan, mulai dari 1 sampai n
- x_i = bobot yang menghubungkan node dengan neuron masukan ke- i
- w_i = nilai masukan ke- i dari node sebelumnya
- n = jumlah keseluruhan fitur

D. Prediksi harga *cryptocurrency*

Pada penelitian ini pengukuran prediksi harga *cryptocurrency* diukur menggunakan Mean Square Error (MSE) untuk mengetahui kedekatan antara nilai aktual dan nilai prediksi dengan rumus MSE sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3)$$

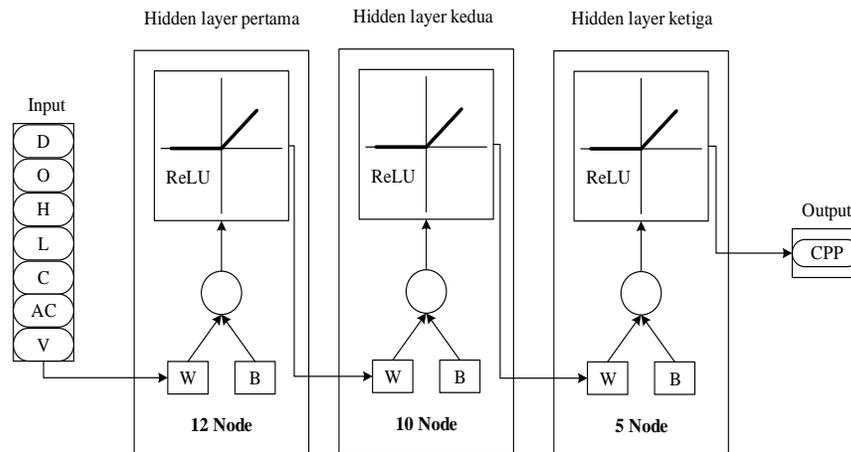
Di mana:

- MSE = kesalahan kuadrat rata-rata
- n = jumlah titik data
- Y_i = nilai yang diamati
- \hat{Y}_i = nilai prediksi

Rumus MSE digunakan untuk mengukur seberapa dekat Y_i prediksi dengan nilai sebenarnya \hat{Y}_i dengan cara menghitung selisih kuadrat antara prediksi dan nilai sebenarnya, kemudian mengambil rata-rata selisih kuadrat tersebut. Semakin kecil nilai MSE maka model prediksinya semakin baik (Lim *et al.* 2016).

Keluaran yang dihasilkan dari model ini berupa variabel nilai prediksi harga *cryptocurrency* selama beberapa periode. Penentuan jumlah periode prediksi menentukan jumlah node pada *hidden layer*. Usulan model arsitektur

berdasarkan periode prediksi tersebut dirancang berdasarkan n periode data historis yang dibaca sebagai input, dan n periode output sebagai hasil prediksi, sehingga terbentuk struktur sebagai berikut:



Gambar 3.6 Arsitektur model ANN yang diusulkan
(Sumber: diolah peneliti)

Gambar di atas menunjukkan bahwa input model usulan mempunyai 7 atribut yaitu *Date* (D), *Open* (O), *High* (H), *Low* (L), *Close* (C), *Adj Close* (AC), dan *Volume* (V) dari data harga *cryptocurrency*. Selain itu, model dirancang menggunakan tiga *hidden layer* dengan 12 node pada *hidden layer* pertama, 10 node pada *hidden layer* kedua, dan 5 node pada *hidden layer* ketiga. Kemudian fungsi aktivasi yang digunakan pada arsitektur model ini adalah ReLU untuk mempercepat proses pelatihan dengan komputasi gradien sederhana dimana setiap elemen negatif diatur nilainya 0,0 sampai minus (-) sehingga tidak terjadi operasi perhitungan perkalian atau pembagian ($f(x) = \max(0, x)$). Dengan demikian, keluaran dari arsitektur model ini adalah prediksi harga *cryptocurrency* (CPP).

Alur kerja pada arsitektur ini adalah data masukan akan diproses pada *hidden layer* pertama dengan masing-masing bobot (W) dan bias (B) untuk setiap neuron diaktifkan dengan ReLU untuk menentukan nilai keluaran setiap neuron. Kemudian keluarannya diterima oleh *hidden layer* ketiga, dan selanjutnya menghasilkan keluaran CPP.

3.1.3.1 Ekstraksi fitur

Ekstraksi fitur merupakan langkah yang dapat dilakukan setelah melewati tahap rekayasa data. Tahap ini merupakan tahap penentuan atribut-atribut yang menjadi dasar pengujian data. Ekstraksi Fitur bertujuan untuk mengurangi jumlah fitur dalam suatu dataset dengan membuat fitur baru dari yang sudah ada dan kemudian menghapus fitur asli. Ekstraksi fitur dapat dilihat pada Tabel 3.4.

Tabel 3.4 Ekstraksi fitur

Atribut	Tipe data	Keterangan
<i>Date</i>	<i>Date</i>	Dikurangi
<i>Open</i>	<i>Numeric</i>	-
<i>High</i>	<i>Numeric</i>	-
<i>Low</i>	<i>Numeric</i>	-
<i>Close</i>	<i>Numeric</i>	-
<i>Adj Close</i>	<i>Numeric</i>	-
<i>Volume</i>	<i>Numeric</i>	-

Tabel 3.4 menunjukkan bahwa terdapat tujuh atribut pada penelitian ini dengan atribut *Date* dikurangi.

3.1.3.2 Proses utama

Langkah-langkah analisis menggunakan model ANN adalah sebagai berikut:

1. Tentukan data input.
2. Tentukan jumlah *hidden layer*.
3. Tentukan *aktivasi function* yang digunakan dalam model *backpropagation*.
4. Perhitungan pembobotan Perhitungan pada fase feedforward.
5. Analisis hasil perhitungan.
6. Dapatkan hasil perhitungan.
7. Menarik kesimpulan dari hasil perhitungan tersebut.

3.1.4 Implementasi Sistem

Dasar dari setiap model ANN adalah node buatan. Model ini memiliki tiga aturan sederhana: perkalian, penjumlahan, dan aktivasi. Pada masukan neuron buatan, masukan tersebut mempunyai bobot yang artinya setiap nilai masukan dikalikan dengan bobot individu. Proses selanjutnya adalah penjumlahan bobot pada input dan bias. Selanjutnya penjumlahan bobot dan bias tersebut akan melewati fungsi aktivasi yang kemudian diteruskan ke keluaran jaringan model ANN.

3.1.5 Eksperimen

Tahap uji coba dilaksanakan menggunakan *Google Colab* untuk memprediksi harga BTC berdasarkan model ANN di masa yang akan datang. Setelah diperoleh hasil prediksi, maka dilakukan analisis terhadap hasil prediksi dengan cara membandingkan hasil prediksi dari ketiga arsitektur model yang diusulkan. Kemudian memilih model dengan tingkat akurasi lebih tertinggi yang dinilai dari parameter MSE, kemudian akan diambil kenodean berdasarkan hasil analisis yang diperoleh.

Secara teori, model ANN tidak memiliki aturan pokok terkait dengan perancangan arsitektur model untuk memperoleh model dengan performa yang baik. Oleh sebab itu, perancangan arsitektur jaringan model dalam penelitian ini dilakukan berdasarkan kebutuhan model dengan cara memodifikikasi jumlah node dan jumlah *hidden layer* yang kemudian dievaluasi dengan formula MSE berdasarkan algoritma *backpropagation*.

Keenam data atribut yang tersedia dibagi menjadi enam kelompok variabel target dengan masing-masing komposisi data terdiri dari 80% sebagai data latih dan 20% sebagai data uji. Lebih jelasnya dapat dilihat pada Tabel 3.5.

Tabel 3.5 Atribut data sebagai variabel target

Model	Atribut	Tipe data	Data latih	Data Uji
A	<i>Open</i>	<i>Numeric</i>	80%	20%
B	<i>High</i>	<i>Numeric</i>	80%	20%
C	<i>Low</i>	<i>Numeric</i>	80%	20%
D	<i>Close</i>	<i>Numeric</i>	80%	20%
E	<i>Adj Close</i>	<i>Numeric</i>	80%	20%
F	<i>Volume</i>	<i>Numeric</i>	80%	20%

Selanjutnya selain membagi keenam atribut yang masing-masing dijadikan sebagai variabel target, penelitian ini juga memvariasikan jumlah node pada *hidden layer* (Tabel 3.6), sehingga akan diperoleh kombinasi untuk proses pelatihan dan pengujian (Tabel 3.7).

Tabel 3.6 Jumlah node pada setiap *hidden layer*

Model	Node	Arsitektur
1	7-5-1	7 input – 5 node – 1 output
2	7-5-10-1	7 input – 5 node – 10 node – 1 output
3	7-5-10-12-1	7 input – 5 node – 10 node – 12 node – 1 output

Uji coba penelitian ini dilakukan sebanyak 18 kali pada masing-masing strategi dengan nama pelatihan yang ditentukan. Selain itu, uji coba penelitian ini dilakukan dengan menggunakan program *Google Colab* untuk memprediksi harga *cryptocurrency* berdasarkan model ANN dengan algoritma *backpropagation*. Selanjutnya hasil prediksi dijelaskan dengan cara membandingkan hasil prediksi dengan nilai sebenarnya. Kemudian diambil kenodean berdasarkan hasil analisis tersebut.

Tabel 3.7 Kombinasi input pada proses pelatihan

Algoritma	Arsitektur	Variabel target	Nama pelatihan
BP	1	A	BP-1A
		B	BP-1B
		C	BP-1C
		D	BP-1D
		E	BP-1E
		F	BP-1F
	2	A	BP-2A
		B	BP-2B
		C	BP-2C
		D	BP-2D
		E	BP-2E
		F	BP-2F
	3	A	BP-3A
		B	BP-3B
		C	BP-3C
		D	BP-3D
		E	BP-3E
		F	BP-3F

3.2 Instrumen Penelitian

Instrumen penelitian berupa gambaran yang berkaitan dengan berbagai parameter yang menjadi pedoman penelitian ini. Parameter yang akan digunakan dalam penelitian ini terdiri dari variabel independen atau variabel terikat, variabel *intervening* atau variabel penghubung, dan variabel dependen atau variabel bebas dapat dilihat pada Tabel 3.8.

Tabel 3.8 Instrumen penelitian

Variabel independen	Main Process	Variable <i>intervening</i>	Variabel dependen
<i>Date, Open price, High price, Low price, and Close price</i>	ANN	Prediksi harga <i>cryptocurrency</i>	Nilai <i>error</i>

Variabel independen atau variabel terikat merupakan variabel yang menjadi fokus utama penelitian. Menurutnya variabel terikat sering disebut dengan variabel keluaran, kriteria, konsekuensi, atau variabel terikat. Variabel terikat adalah variabel yang dipengaruhi atau akibat dari adanya variabel bebas tersebut. Dalam penelitian ini variabel terikatnya adalah nilai error.

Variabel *intervening* atau variabel penghubung merupakan variabel yang secara teoritis mempengaruhi hubungan antara variabel bebas dan variabel terikat menjadi hubungan tidak langsung dan tidak dapat diamati dan diukur. Variabel ini merupakan variabel *intervening*/perantara yang terletak di antara variabel independen dan dependen sehingga variabel independen tidak mempengaruhi secara langsung terhadap perubahan atau munculnya variabel dependen. Variabel *intervening* dalam penelitian ini adalah prediksi harga *cryptocurrency*.

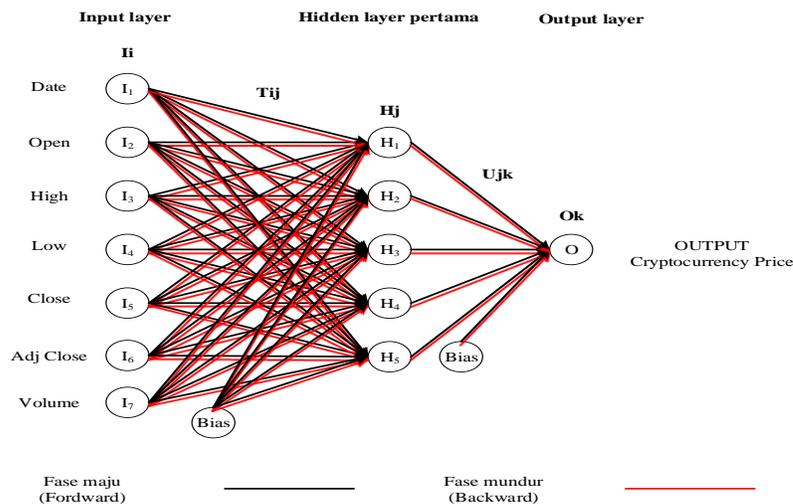
Variabel dependen atau variabel bebas adalah variabel yang mempengaruhi atau menjadi penyebab perubahan dan timbulnya variabel terikat. Variabel independen dalam penelitian ini adalah *Date, Open price, High price, Low price, and Close price*.

BAB IV

MODEL ANN SATU *HIDDEN LAYER*

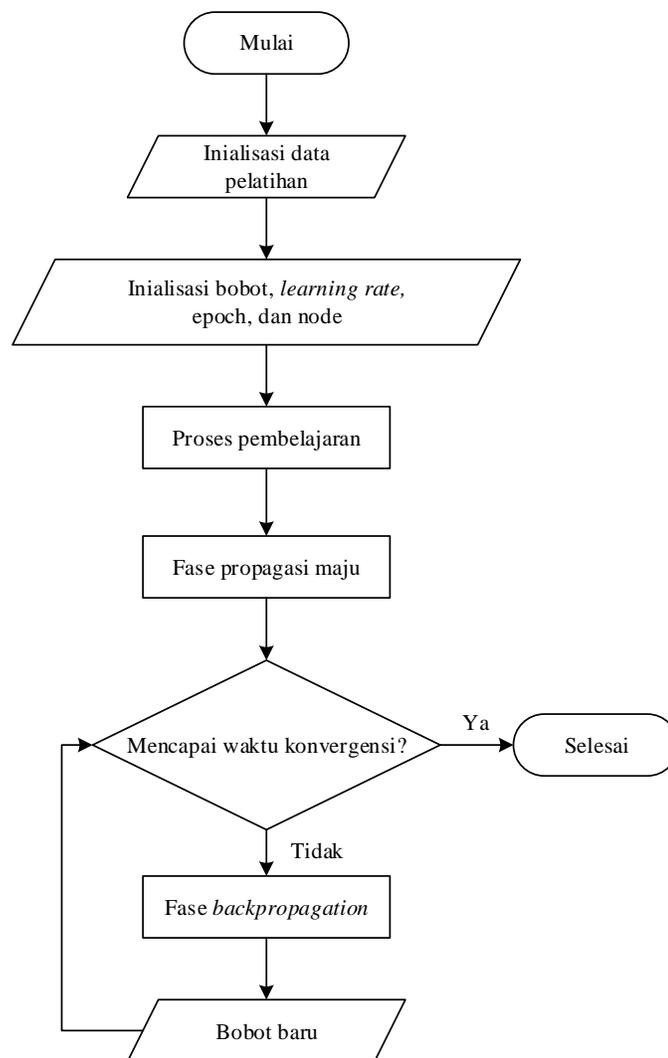
4.1 Desain

Desain merupakan rangkaian tahapan proses yang dilakukan oleh penelitian yang bertujuan untuk memecahkan permasalahan penelitian. Dengan tahapan tersebut objek dalam penelitian dapat terlihat dengan jelas yang kemudian dapat dijadikan landasan dasar dalam pengambilan kesimpulan. Dalam hal ini peneliti menggunakan model ANN algoritma *Backpropagation* untuk memprediksi harga *cryptocurrency* berdasarkan data harga BTC pada periode 29 November – 19 Maret 2023. Strategi pertama dengan satu *hidden layer* pada desain jaringan ANN algoritma *Backpropagation* terdiri dari data masukan (I_i) berupa data harga *cryptocurrency*, nilai pembobotan antara *input layer* ke *hidden layer* pertama (T_{ij}), hasil keluaran pada *hidden layer* pertama yang jumlah nodenya sudah ditentukan (H_j), nilai pembobotan antara *hidden layer* pertama dan outputnya (U_{jk}), dan nilai outputnya berupa harga *cryptocurrency* (O_k). Lebih jelasnya dapat dilihat pada Gambar 4.1 dibawah ini:



Gambar 4.1 Desain jaringan model ANN dengan satu *hidden layer*

Strategi pertama yang digunakan untuk memprediksi harga *cryptocurrency* menggunakan satu *hidden layer* (7-5-1) berdasarkan model ANN dengan algoritma *backpropagation*. Model ANN *backpropagation* merupakan salah satu teknik pembelajaran yang termasuk dalam supervisi pembelajaran. Proses pelatihan menggunakan *Mean Square Error* (MSE) sebagai penghentian proses dan bobot akhir untuk mendapatkan bobot optimal. Artinya proses pelatihan akan berhenti jika waktu konvergensi telah tercapai. Selanjutnya tahapan *flowchart* pelatihan pada strategi pertama dalam prediksi harga *cryptocurrency* dapat dilihat pada Gambar 4.2.



Gambar 4.2 *Flowchart* proses pelatihan

Sumber: diolah oleh peneliti

Langkah-langkah perhitungan pada strategi pertama diantaranya adalah:

1. Inisialisasi data *input*
2. Inisialisasi parameter model
3. Fase propagasi maju
 - Hitung sinyal dari setiap node pada *hidden layer* (H_j). Pada fase ini informasi diberikan kepada variabel masukan (I_i) yang kemudian melanjutkan sinyal masukan ke semua *hidden layer*.

$$H_{net\ j} = T_{0j} + \sum_{i=1}^n I_i T_{ij} \quad (1)$$

Dimana i node ke- i ($i = 1, 2, 3, \dots, n$) di dalam *input layer* dan j node ke- j ($j = 1, 2, 3, \dots, p$) di dalam *hidden layer* pertama. I_i merupakan nilai *input* di dalam node masukan i ke node tersembunyi j . T_{0j} merupakan bias di dalam *input layer* dan T_{ij} merupakan bobot di dalam node masukan i yang mengarah ke node j .

- Semua keluaran pada *hidden layer* pertama dihitung menggunakan ReLU. Hasilnya diaplikasikan pada setiap node di dalam *hidden layer* pertama untuk proses berikutnya.

$$H_j = f(H_{net\ j}) = \max(0, H_{net\ j}) \quad (2)$$

Dengan max sebagai nilai maksimum antara 0 dan $H_{net\ j}$. Hasil perhitungan $f(H_{net\ j})$ adalah nilai aktivasi di dalam node tersembunyi j yang kemudian didistribusikan ke semua node keluaran.

- Setelah diperoleh nilai setiap *hidden layer*, kemudian dijumlahkan seluruh sinyal yang masuk ke keluaran ($H_j \dots H_n$) dengan bobotnya.

$$O_{net\ k} = U_{0k} + \sum_{j=1}^n H_j U_{jk} \quad (3)$$

U_{0k} adalah nilai bias pada *hidden layer*, H_j adalah hasil yang keluar dari *hidden layer*, dan U_{jk} adalah bobot pada node tersembunyi j yang mengarah ke node keluaran k ($k = 1, 2, 3, \dots, m$).

- Dengan menggunakan fungsi aktivasi ReLU untuk menghitung sinyal keluaran, maka nilai yang diperoleh adalah:

$$O_k = f(O_{net\ k}) = \max(0, O_{net\ k}) \quad (4)$$

$O_{net\ k}$ merupakan hasil dari fungsi aktivasi yaitu penjumlahan bobot antara node tersembunyi dan node keluaran.

4. Setelah nilai keluaran dihasilkan, selisihnya dengan nilai keluaran target dihitung menggunakan persamaan MSE.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5)$$

Jika waktu konvergensi telah tercapai, maka proses akan berhenti. Sebaliknya jika waktu konvergensi belum tercapai, maka dilakukan proses *backpropagation* dengan memperbarui bobot.

5. Fase Propagasi Balik

- Hitung nilai error (δ_k) pada lapisan keluaran (O_k) yang menerima pola target (t_k) yang kemudian dikirim ke lapisan berikutnya yang digunakan untuk menghitung bobot dan koreksi bias antara *input layer* dan *hidden layer*.

$$\delta_k = (t_k - O_k) f'(O_{net\ k}) \quad (6)$$

Dimana:

$$f'(O_{net\ k}) = (1 - f(O_{net\ k}))f(O_{net\ k}) \quad (7)$$

- Setelah nilai error pada *hidden layer* pertama dan lapisan keluaran diperoleh, dilanjutkan dengan menghitung kesalahan pada *input layer* dan *hidden layer* pertama.

$$\delta_j = \delta_{net\ j} f'(H_{net\ j}) \quad (8)$$

Dimana:

$$\delta_{net\ j} = \sum_{k=1}^m \delta_k U_{jk} \quad (9)$$

$$f'(H_{net\ j}) = (1 - f(H_{net\ j}))f(H_{net\ j}) \quad (10)$$

- Setelah nilai error setiap lapisan diketahui, maka jumlah perubahan atau koreksi yang akan ditambahkan pada bobot lama dapat dihitung.

$$\Delta T_{ij} = \alpha \delta_j I_i \quad (11)$$

$$\Delta U_{jk} = \alpha \delta_k H_j \quad (12)$$

ΔT_{ij} dan ΔU_{jk} adalah perubahan yang akan ditambahkan pada bobot lama yang akan diperbarui dengan α learning rate, δ_j adalah kesalahan yang terjadi antara *input layer* dan *hidden layer*, dan δ_k adalah kesalahan antara *hidden layer* dan lapisan keluaran. I_i adalah input yang berasal dari node i ke node j , sedangkan H_j merupakan hasil aktivasi fungsi dari *hidden layer*.

6. Fase perubahan bobot

Setelah ΔT_{ij} dan ΔU_{jk} diperoleh, langkah selanjutnya adalah memperbaiki bobot lama menjadi bobot baru .

$$T_{ij}(new) = T_{ij}(old) + \Delta T_{ij} \quad (13)$$

$$U_{jk}(new) = U_{jk}(old) + \Delta U_{jk} \quad (14)$$

$T_{ij}(new)$ adalah bobot baru antara *input layer* dan *hidden layer* pertama yang akan dicari, sedangkan $T_{ij}(old)$ adalah bobot lama yang akan diperbarui. $U_{jk}(new)$ adalah bobot baru antara *hidden layer* pertama dan lapisan keluaran yang akan dicari, sedangkan $U_{jk}(old)$ adalah bobot lama yang akan diperbarui.

4.2 Implementasi

Pembuatan jaringan diprogram dengan dengan *Google Colab*. Model terdiri dari satu *hidden layer* dengan total 5 node. Pada proses evaluasi, optimalisasi jaringan diproses berdasarkan nilai MSE terkecil pada saat pembelajaran dengan memvariasikan setiap atribut menjadi variabel target dan menentukan jumlah node *hidden layer* pada strategi pertama. Parameter pelatihan yang digunakan dapat dilihat pada Tabel 4.1.

Tabel 4.1 Parameter model

Tipe jaringan	BP-ANN
Fungsi aktivasi	ReLU
Optimizer	Adam
Persamaan	MSE
Input layer	7
<i>Hidden layer</i>	1 <i>Hidden layer</i>
Node <i>hidden layer</i>	5
Output layer	1
Learning rate	0.2

4.3 Uji coba

Pelatihan model dilaksanakan menggunakan data input pelatihan dan pengujian sekitar 80% untuk data pelatihan dan 20% untuk data pengujian dari hasil normalisasi yang selanjutnya selanjutnya digunakan untuk proses pengujian model. Selain itu, proses pelatihan dilakukan dengan memvariasikan setiap atribut yang dijadikan variabel target kecuali atribut *Date* (D).

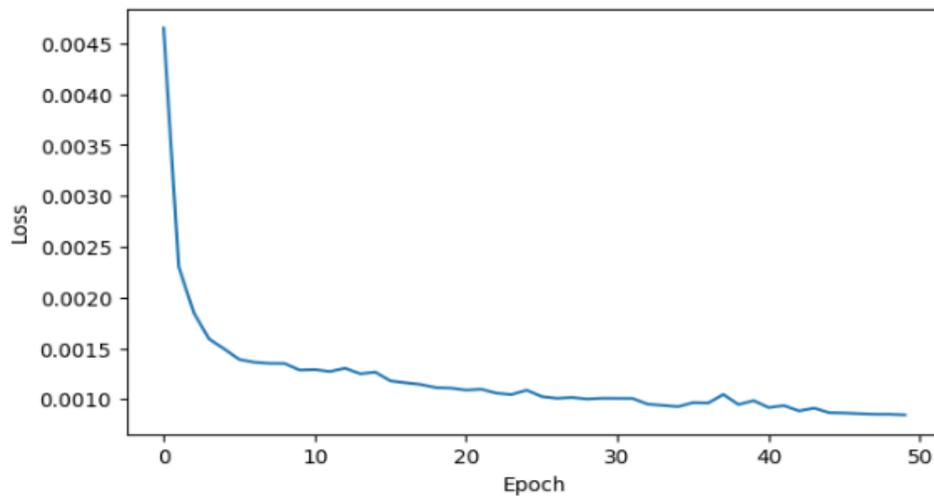
4.3.1 Pelatihan BP-1A

Hasil dari pelatihan BP-1A dengan menggunakan atribut *Open* (O) sebagai variabel target dapat dilihat pada Tabel 4.2.

Tabel 4.2 Proses pelatihan BP-1A

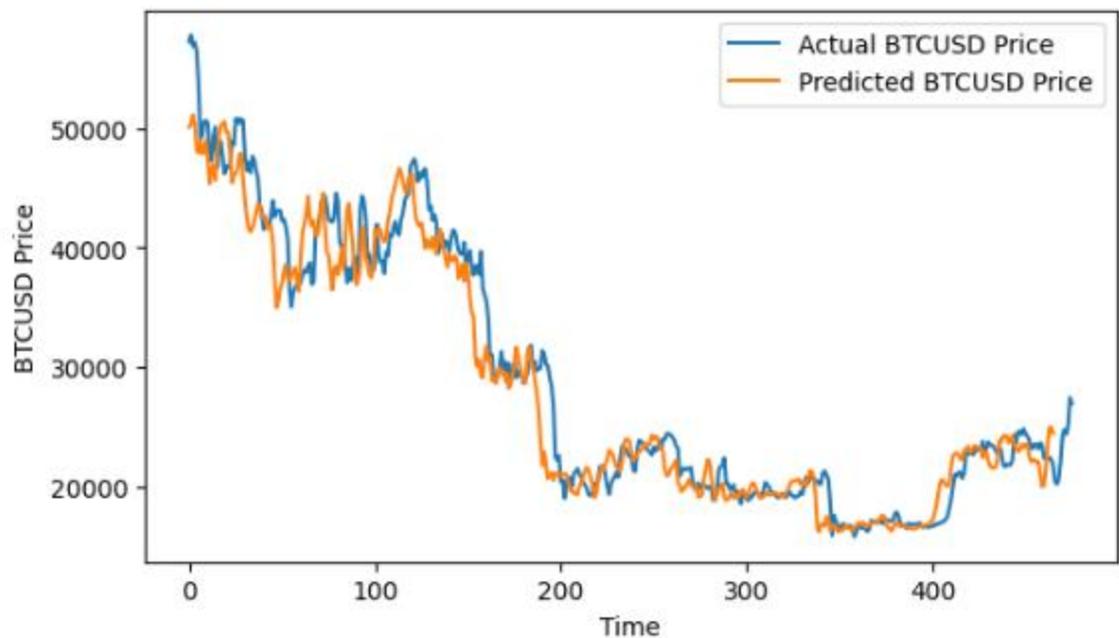
Epoch	Waktu konvergensi	MSE	Val_loss
1	204 <i>ms/step</i>	0,0047	0,0025
2	6 <i>ms/step</i>	0,0023	0,0019
3	4 <i>ms/step</i>	0,0018	7.3618e ⁻⁰⁴
...
48	5 <i>ms/step</i>	8.5179e ⁻⁰⁴	3.7351e ⁻⁰⁴
49	6 <i>ms/step</i>	8.5110e ⁻⁰⁴	4.0511e ⁻⁰⁴
50	6 <i>ms/step</i>	8.4467e ⁻⁰⁴	4.0431e ⁻⁰⁴

Tabel 4.2 menunjukkan bahwa proses pelatihan BP-1A dapat dijalankan selama 6 *ms/step* dengan nilai MSE sebesar 8.4467e⁻⁰⁴ atau sekitar 0.000844 dan nilai *validation_loss* sebesar 4.0431e⁻⁰⁴ atau sekitar 0.000404. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.3.



Gambar 4.3 Nilai loss pelatihan BP-1A

Grafik perbandingan antara keluaran pelatihan BP-1A berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 4.4 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.4 Perbandingan harga prediksi dengan data harga aktual BP-1A

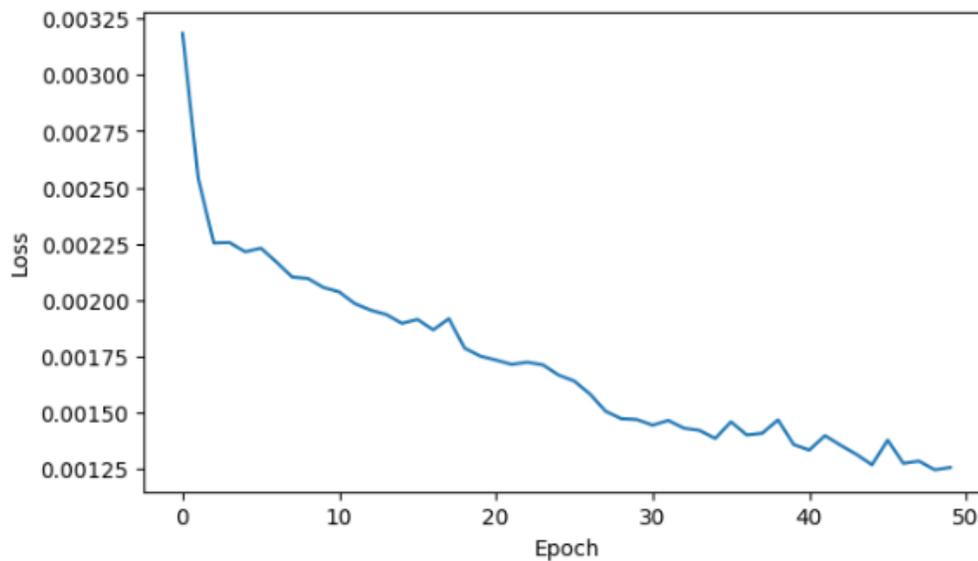
4.3.2 Pelatihan BP-1B

Hasil dari pelatihan BP-1B dengan menggunakan atribut *High* (H) sebagai variabel target dapat dilihat pada Tabel 4.3.

Tabel 4.3 Proses pelatihan BP-1B

Epoch	Waktu kovergensi	MSE	Val_loss
1	23 ms/step	0,0032	0,0012
2	5 ms/step	0,0025	9.8924e ⁻⁰⁴
3	5 ms/step	0,0013	9.8945e ⁻⁰⁴
...
48	6 ms/step	0,0013	6.3982e ⁻⁰⁴
49	5 ms/step	0,0012	6.3790e ⁻⁰⁴
50	5 ms/step	0,0013	7.0668e ⁻⁰⁴

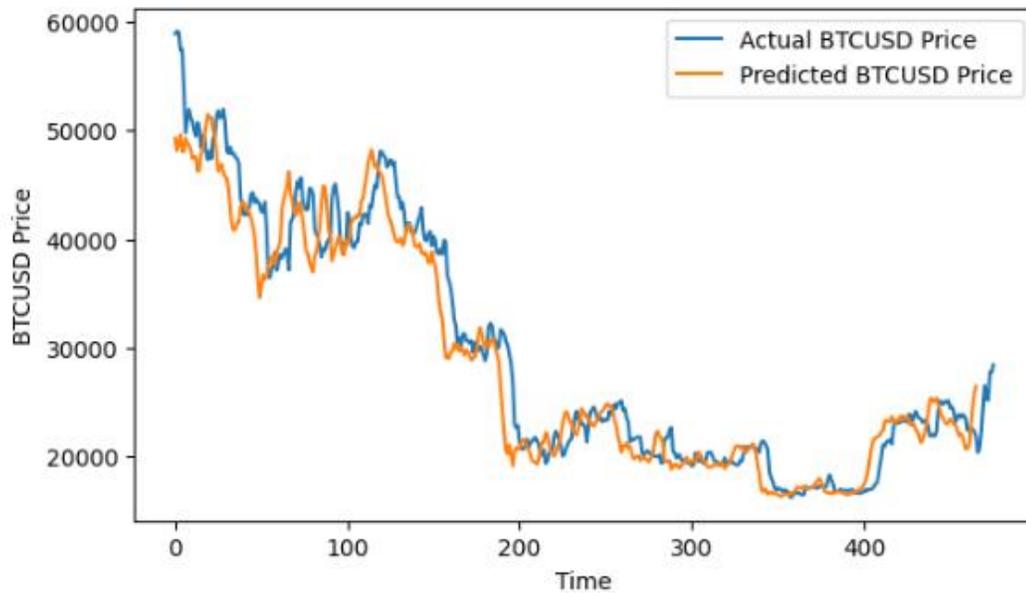
Tabel 4.3 menunjukkan bahwa proses pelatihan BP-1B dapat dijalankan selama 5 ms/step dengan nilai MSE sekitar 0.0013 dan nilai *validation_loss* 7.0668e⁻⁰⁴ atau sekitar 0.000706. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.5.



Gambar 4.5 Nilai loss pelatihan BP-1B

Grafik perbandingan antara keluaran pelatihan BP-1B berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 4.6

memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.6 Perbandingan harga prediksi dengan data harga aktual BP-1B

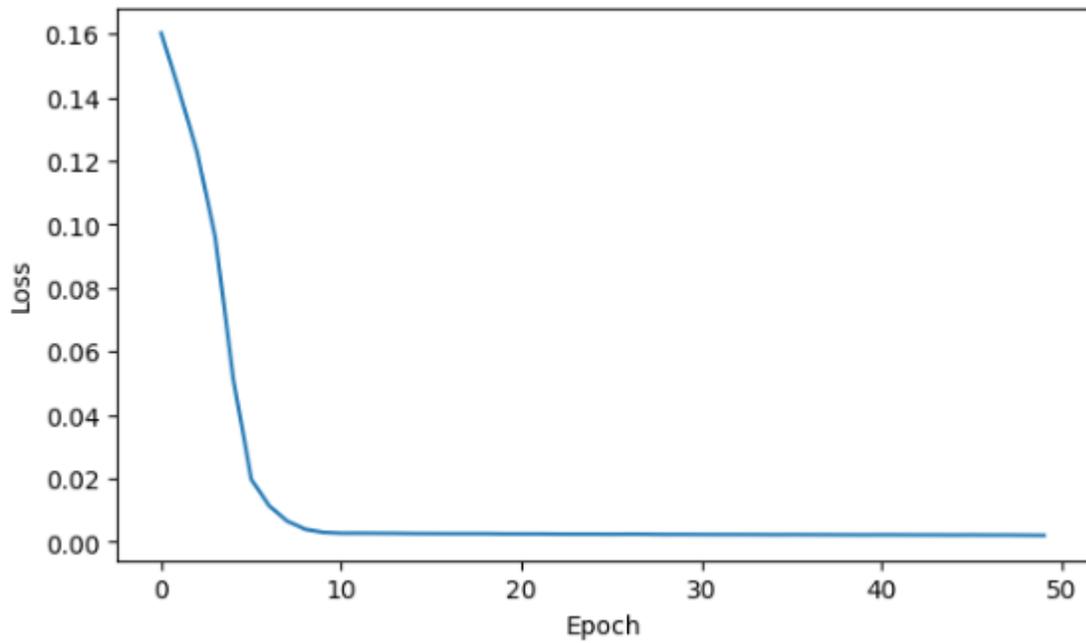
4.3.3 Pelatihan BP-1C

Hasil dari pelatihan BP-1C dengan menggunakan atribut *Low* (L) sebagai variabel target dapat dilihat pada Tabel 4.4.

Tabel 4.4 Proses pelatihan BP-1C

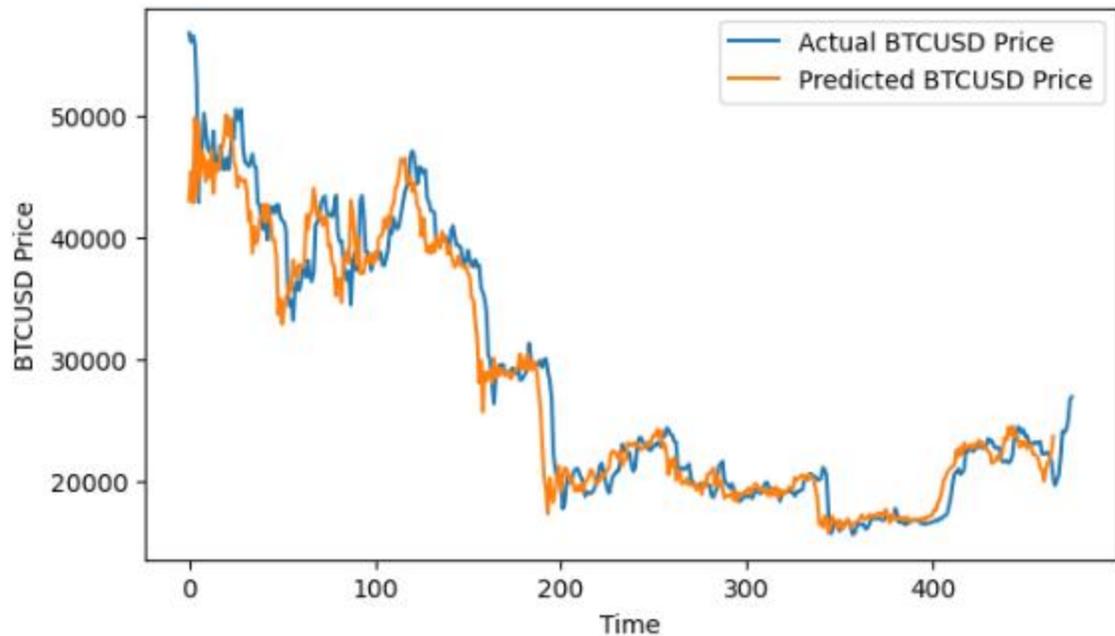
Epoch	Waktu konvergensi	MSE	Val_loss
1	19 <i>ms/step</i>	0.1603	0.0147
2	5 <i>ms/step</i>	0.1420	0.0095
3	5 <i>ms/step</i>	0.1226	0.0054
...
48	7 <i>ms/step</i>	0.0022	9.1264e ⁻⁰⁴
49	7 <i>6ms/step</i>	0.0022	8.7692e ⁻⁰⁴
50	6 <i>ms/step</i>	0.0021	7.5213e ⁻⁰⁴

Tabel 4.4 menunjukkan bahwa proses pelatihan BP-1C dapat dijalankan selama 6 *ms/step* dengan nilai MSE sekitar 0.0021 dan nilai *validation_loss* 7.5213e⁻⁰⁴ atau sekitar 0,000752. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.7.



Gambar 4.7 Nilai loss pelatihan BP-1C

Grafik perbandingan antara keluaran pelatihan BP-1C berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 4.8 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.8 Perbandingan harga prediksi dengan harga aktual BP-1C

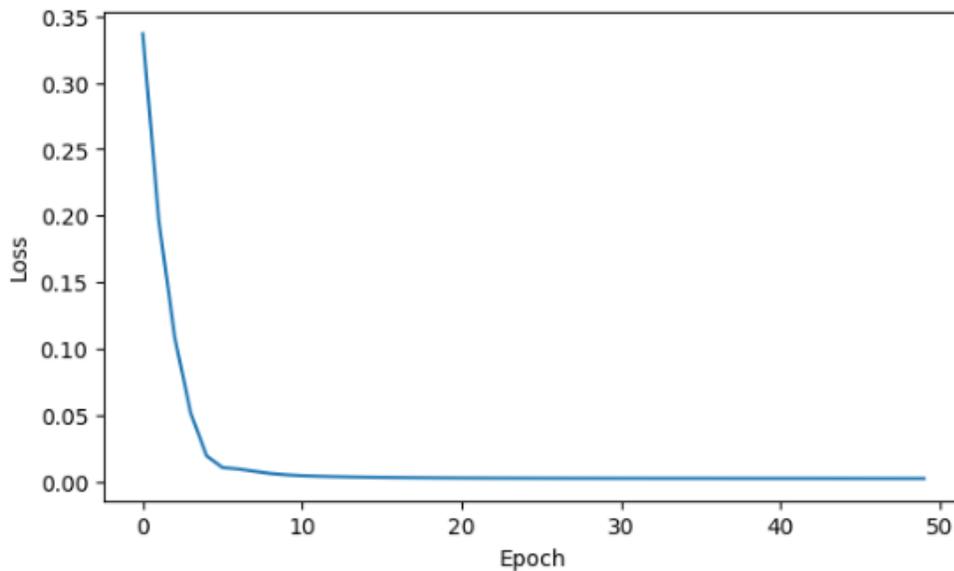
4.3.4 Pelatihan BP-1D

Hasil dari pelatihan BP-1D dengan menggunakan atribut *Close* (C) sebagai variabel target dapat dilihat pada Tabel 4.5.

Tabel 4.5 Proses pelatihan BP-1D

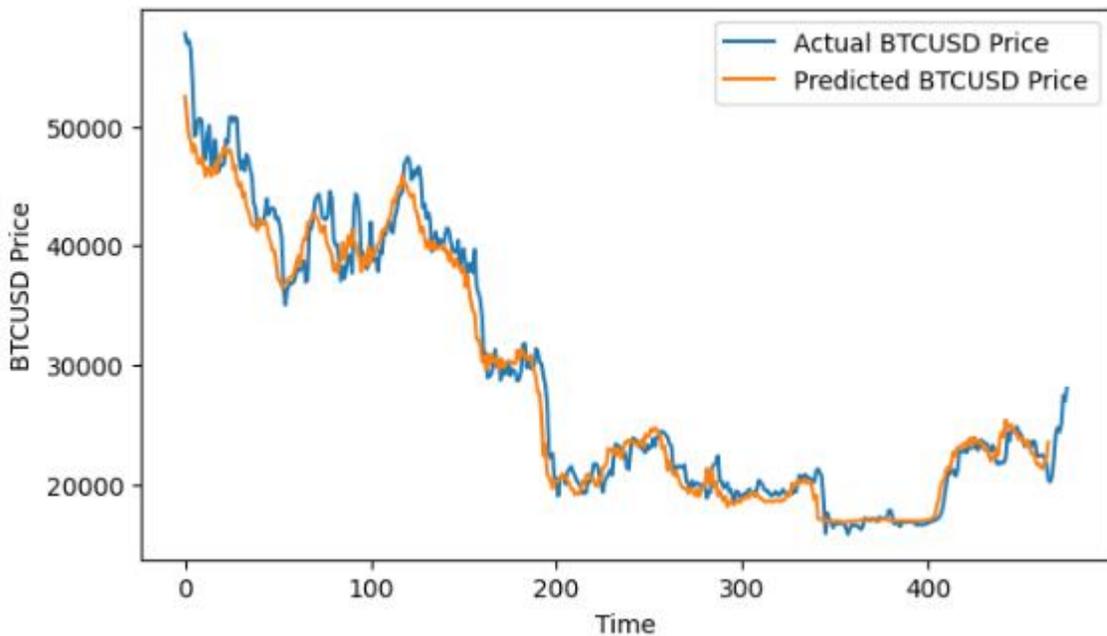
Epoch	Waktu konvergensi	MSE	Val_loss
1	5 ms/step	0.0028	0.0015
2	6 ms/step	0.0028	0.0015
3	6 ms/step	0.0027	0.0015
...
48	7 ms/step	0.0025	0.0016
49	9 ms/step	0.0025	0.0015
50	8 ms/step	0.0025	0.0015

Tabel 4.5 menunjukkan bahwa proses pelatihan BP-1D dapat dijalankan selama 8 *ms/step* dengan nilai MSE sekitar 0,0025 dan nilai *validation_loss* sekitar 0,0015. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.9.



Gambar 4.9 Nilai loss pelatihan BP-1D

Grafik perbandingan antara keluaran pelatihan BP-1D berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 4.10 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.10 Perbandingan harga prediksi dengan harga aktual BP-1D

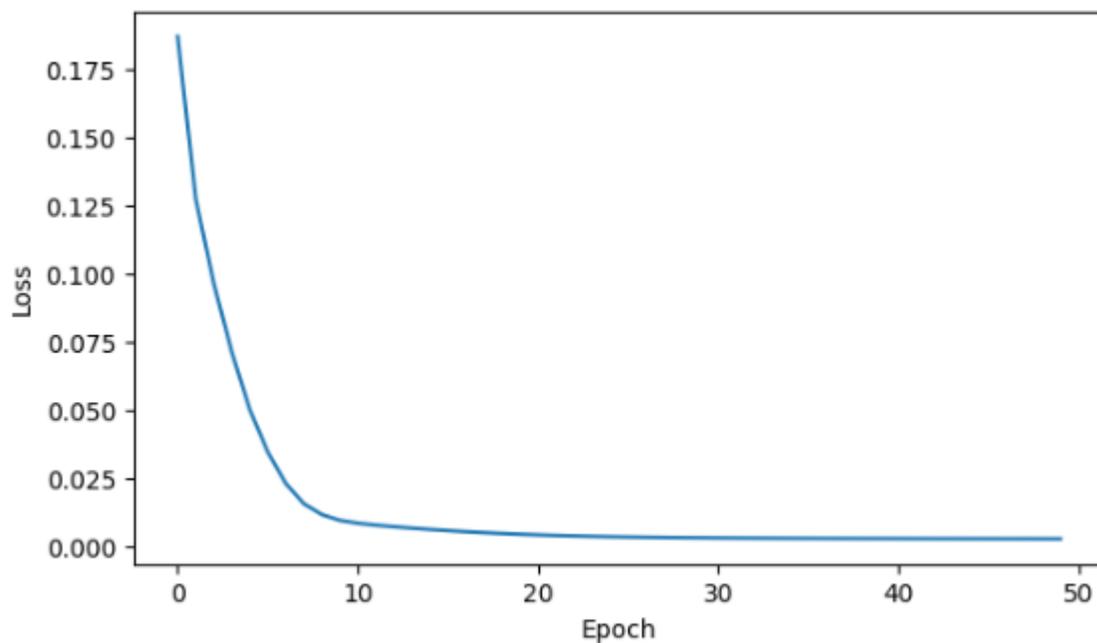
4.3.5 Pelatihan BP-1E

Hasil dari pelatihan BP-1E dengan menggunakan atribut *Adj Close* (AC) sebagai variabel target dapat dilihat pada Tabel 4.6.

Tabel 4.6 Proses pelatihan BP-1E

Epoch	Waktu konvergensi	MSE	Val_loss
1	158 <i>ms/step</i>	0.1868	0.0014
2	6 <i>ms/step</i>	0.1237	0.0082
3	6 <i>ms/step</i>	0.0963	0.0044
...
48	5 <i>ms/step</i>	0.0025	0.0015
49	5 <i>ms/step</i>	0.0025	0.0015
50	4 <i>ms/step</i>	0.0025	0.0015

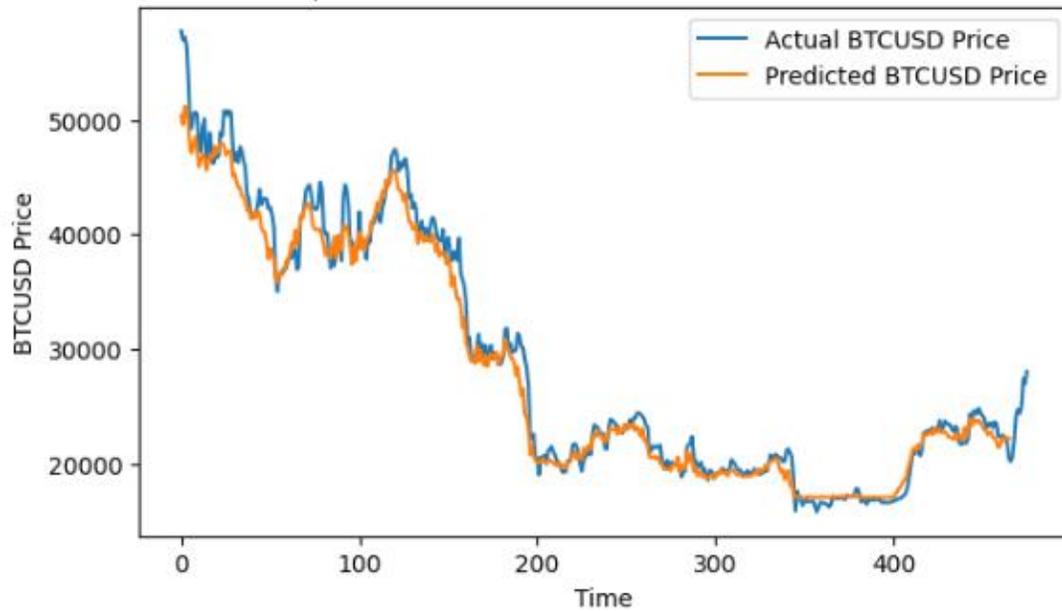
Tabel 4.6 menunjukkan bahwa proses pelatihan BP-1E dapat dijalankan selama 4 *ms/step* dengan nilai MSE sekitar 0,0025 dan nilai *validation_loss* sekitar 0,0015. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.11.



Gambar 4.11 Nilai loss pelatihan BP-1E

Grafik perbandingan antara keluaran pelatihan BP-1E berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 4.12

memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.12 Perbandingan harga prediksi dengan harga aktual BP-1E

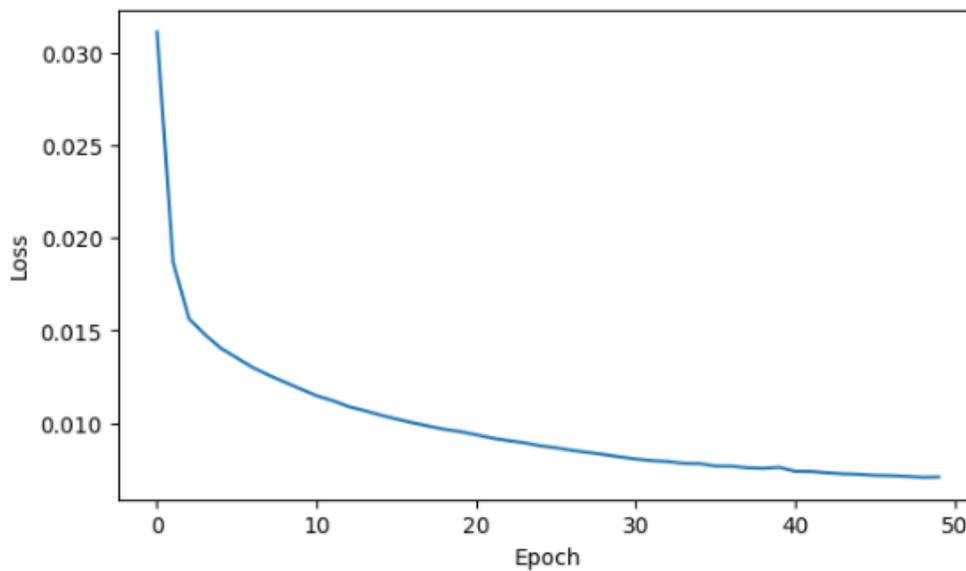
4.3.6 Pelatihan BP-1F

Hasil dari pelatihan BP-1F dengan menggunakan atribut *Volume* (V) sebagai variabel target dapat dilihat pada Tabel 4.7.

Tabel 4.7 Proses pelatihan BP-1F

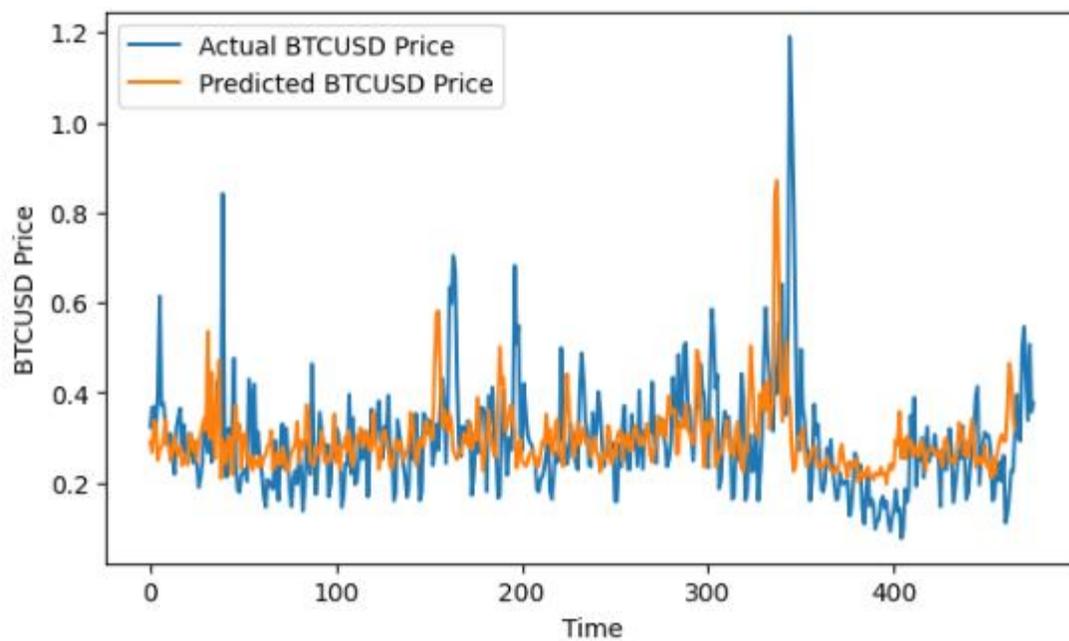
Epoch	Waktu konvergensi	MSE	Val_loss
1	136 <i>ms/step</i>	0.031	0.0105
2	6 <i>ms/step</i>	0.1237	0.0075
3	6 <i>ms/step</i>	0.0963	0.0075
...
48	4 <i>ms/step</i>	0.0071	0.0048
49	6 <i>ms/step</i>	0.0071	0.0046
50	6 <i>ms/step</i>	0.0071	0.0046

Tabel 4.7 menunjukkan bahwa proses pelatihan BP-1F dapat dijalankan selama 6 *ms/step* dengan nilai MSE sekitar 0.0071 dan nilai *validation_loss* sekitar 0.0046. Hasil *plotting* grafis dari proses ini dapat dilihat pada Gambar 4.13.



Gambar 4.13 Nilai loss pelatihan BP-1F

Grafik perbandingan antara keluaran pelatihan BP-1F berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 4.14 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 4.14 Perbandingan harga prediksi dengan harga aktual BP-1F

4.4 Hasil Prediksi

Setelah melakukan proses pelatihan pada masing-masing model, dilanjutkan dengan proses pengujian. Proses ini dilaksanakan untuk mengetahui performa terbaik dari arsitektur model dan untuk mengetahui pengaruh atribut terhadap prediksi harga *cryptocurrency* berdasarkan model ANN. Hasil proses pengujian disajikan pada Tabel 4.8.

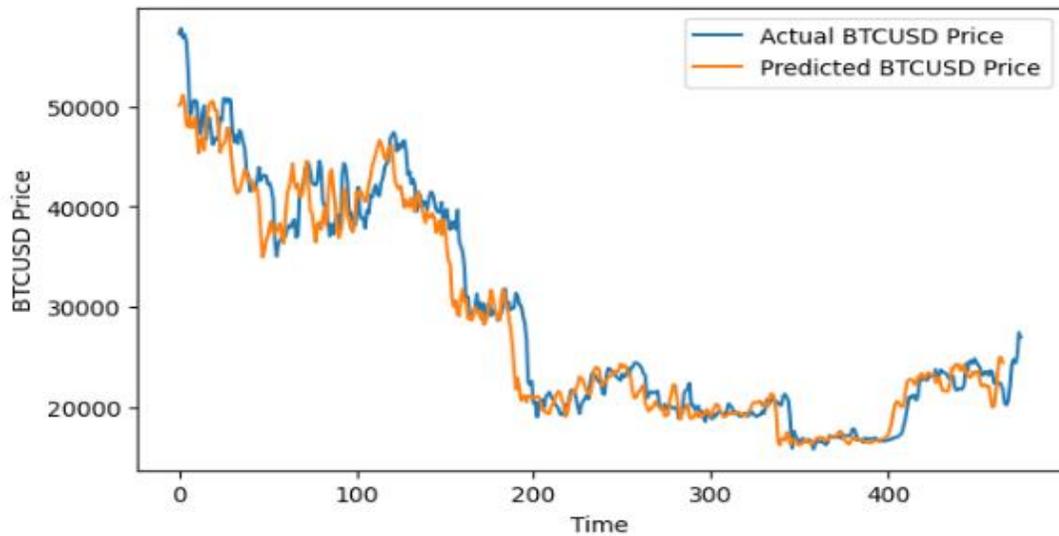
Tabel 4.8 Hasil prediksi model BP-ANN pada strategi pertama

Pelatihan	Arsitektur	Waktu konvergensi	MSE
BP-1A	7-5-1	6 ms/step	4.0431e⁻⁰⁴
BP-1B	7-5-1	5 ms/step	7.0668e ⁻⁰⁴
BP-1C	7-5-1	6 ms/step	7.5213e ⁻⁰⁴
BP-1D	7-5-1	8 ms/step	0.0015
BP-1E	7-5-1	4 ms/step	0.0015
BP-1F	7-5-1	6 ms/step	0.0046

Tabel 4.8 menunjukkan bahwa hasil prediksi model **BP-1A** menggunakan satu *hidden layer* (7-5-1) menunjukkan performa terbaik pada saat proses pelatihan dan pengujian model dengan nilai MSE sekitar $4.0431e^{-04}$ atau sekitar 0.000404. Hal ini menunjukkan bahwa penggunaan satu *hidden layer* dalam model ANN untuk memprediksi harga *cryptocurrency* sudah cukup untuk memenuhi target output. Hal ini sejalan dengan penelitian yang dilakukan oleh Fausett (1994) yang menyatakan bahwa satu *hidden layer* sudah cukup untuk menghasilkan output yang memenuhi target.

4.5 Kesimpulan

Hasil prediksi harga *cryptocurrency* pada strategi pertama dengan satu *hidden layer* memiliki pola grafik yang mirip dibandingkan dengan nilai sebenarnya. Hal ini menunjukkan bahwa model ANN dengan algoritma *backpropagation* sangat efektif untuk melakukan prediksi harga *cryptocurrency* yang ditandai dengan terutama pada proses pelatihan BP-1A.



Gambar 4.15 Grafik perbandingan model terbaik pada strategi pertama

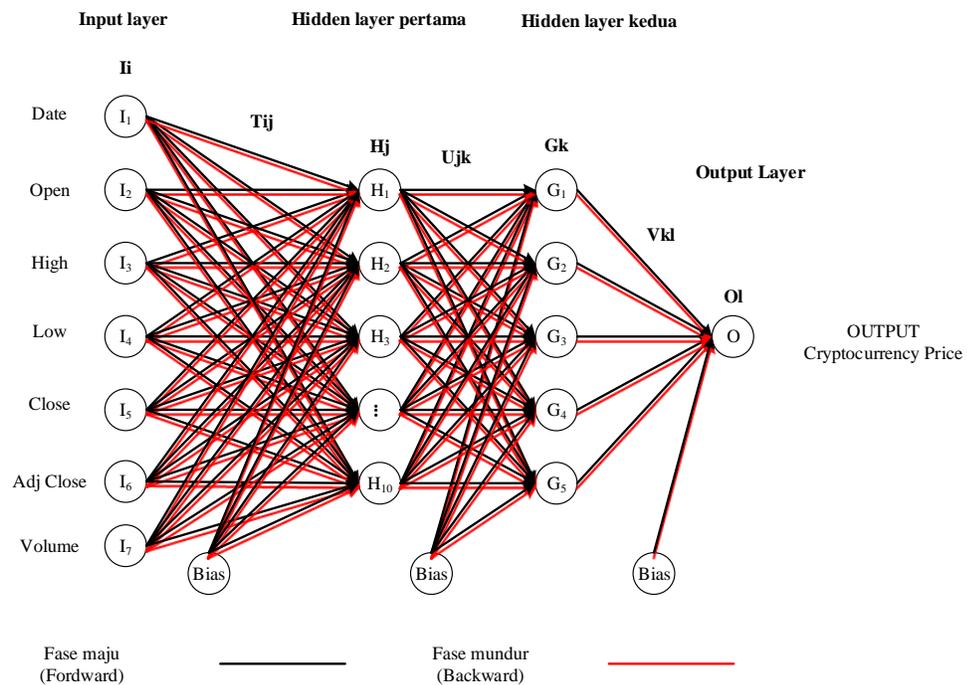
Berdasarkan uraian pada Tabel 4.8 dapat dinodekan bahwa model BP-A1 merupakan model dengan arsitektur terbaik yang dilatih menggunakan algoritma *backpropagation*. Selama proses pengujian, model ini memberikan hasil terbaik dibandingkan model lainnya, ditandai dengan diperolehnya nilai MSE sekitar $4.0431e^{-04}$ atau sekitar 0.000404.

BAB V

MODEL ANN DUA *HIDDEN LAYER*

5.1 Desain

Strategi kedua dengan perancangan jaringan dua *hidden layer* pada algoritma *backpropagation* ANN terdiri dari data masukan (I_i) berupa data harga *cryptocurrency*, nilai pembobotan antara *input layer* ke *hidden layer* pertama (T_{ij}), hasil keluaran pada *hidden layer* pertama lapisan yang telah ditentukan jumlah nodenya (H_j), nilai bobot antara *hidden layer* pertama dan *hidden layer* kedua (U_{jk}), hasil keluaran *hidden layer* kedua yang jumlah nodenya telah ditentukan (G_k), nilai bobot antara *hidden layer* kedua dan keluaran (V_{kl}), dan nilai keluaran berupa harga *cryptocurrency* (O_l). Lebih jelasnya dapat dilihat pada Gambar 5.1 di bawah ini:



Gambar 5.1 Desain jaringan model ANN dengan dua *hidden layer*

Strategi kedua yang digunakan untuk memprediksi harga *cryptocurrency* menggunakan dua *hidden layer* (7-10-5-1) berdasarkan model ANN dengan algoritma *backpropagation*.

Langkah-langkah perhitungan strategi kedua adalah sebagai berikut:

1. Mulai
2. Inisialisasi data pelatihan setelah dinormalisasi
3. Bobot inisialisasi dan jumlah nodenya.
4. Fase Propagasi Maju
 - Hitung sinyal dari setiap node pada *hidden layer* pertama (H_j). Pada fase ini, informasi diberikan kepada variabel masukan (I_i) kemudian variabel ini akan meneruskan sinyal masukan ke seluruh *hidden layer*.

$$H_{net\ j} = T_{0j} + \sum_{i=1}^n I_i T_{ij} \quad (1)$$

Dengan i adalah node ke- i ($i= 1, 2, 3, \dots, n$) pada *input layer* dan j merupakan node ke- j ($j= 1, 2, 3, \dots, p$) pada *hidden layer* pertama. I_i adalah nilai masukan pada node masukan i ke node tersembunyi j . T_{0j} adalah bias pada *input layer* dan T_{ij} merupakan bobot pada node masukan i yang menuju ke neuron j .

- Semua keluaran pada *hidden layer* pertama dihitung menggunakan ReLU . Hasilnya akan digunakan oleh setiap pada *hidden layer* pertama dan kemudian masuk ke *hidden layer* kedua (G_k).

$$H_j = f(H_{net\ j}) = \max(0, H_{net\ j}) \quad (2)$$

Dengan maks sebagai tanda maksimum antara 0 dan $H_{net\ j}$. Hasil dari perhitungan $f(H_{net\ j})$ adalah nilai aktivasi pada node j yang tersembunyi yang kemudian dikirimkan ke seluruh node keluaran.

- Selanjutnya, hitung sinyal dari setiap node *hidden layer* kedua (G_k). Dalam fase informasi diberikan pada input(H_j) variabel maka variabel ini akan meneruskan sinyal masukan ke semua *hidden layer*.

$$G_{net\ k} = U_{0k} + \sum_{j=1}^n H_j U_{jk} \quad (3)$$

Dengan i adalah node ke- i ($j= 1, 2, 3, \dots, n$) pada *input layer* dan k merupakan node ke- k ($k= 1, 2, 3, \dots, p$) pada *hidden layer* kedua. H_j adalah nilai masukan pada node masukan j ke node tersembunyi k . U_{0k} adalah bias pada *input layer* dan U_{jk} merupakan bobot pada node masukan j yang menuju ke neuron k .

- Semua keluaran pada *hidden layer* kedua dihitung menggunakan ReLU. Hasilnya akan digunakan oleh setiap node pada *hidden layer* kedua yang kemudian masuk pada proses selanjutnya.

$$G_k = f(G_{net\ k}) = \max(0, G_{net\ k}) \quad (4)$$

Dengan maks sebagai tanda maksimum antara 0 dan $G_{net\ k}$. Hasil dari perhitungan $f(G_{net\ k})$ adalah nilai aktivasi pada neuron tersembunyi k yang kemudian dikirimkan ke seluruh node keluaran.

- Setelah diperoleh tanda pada setiap detik *hidden layer* selanjutnya dijumlahkan seluruh sinyal masuk ke -output ($G_k \dots G_n$) dengan bobotnya.

$$O_{net\ l} = V_{0l} + \sum_{k=1}^n G_k V_{kl} \quad (5)$$

V_{0l} adalah nilai bias pada *hidden layer* dan G_k merupakan hasil yang keluar dari *hidden layer* kedua dan V_{kl} merupakan bobot dari node tersembunyi k menuju ke neuron keluaran l ($l= 1, 2, 3, \dots, m$).

- Dengan menggunakan fungsi Aktivasi ReLU Untuk menghitung sinyal keluaran, maka tepat diperoleh tanda yaitu:

$$O_l = f(O_{net\ l}) = \max(0, O_{net\ l}) \quad (6)$$

$O_{net\ l}$ merupakan hasil dari fungsi Aktivasi yaitu penjumlahan bobot antara node *hidden layer* kedua dan node keluaran.

5. Setelah dihasilkan nilai keluaran kemudian dihitung selisihnya dengan nilai keluaran target menggunakan persamaan MSE.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (7)$$

Jika waktu konvergensi telah tercapai, maka proses akan terhenti. Sebaliknya jika waktu konvergensi belum tercapai, maka dilakukan proses *backpropagation* dengan memperbarui bobot.

6. Fase Propagasi Balik

- Lakukan perhitungan faktor nilai error (δ_l) pada lapisan keluaran (O_l) yang menerima pola target (t_l) kemudian dikirim ke lapisan berikutnya yang digunakan untuk menghitung koreksi bobot dan bias antara *input layer* dan *hidden layer*.

$$\delta_l = (t_l - O_l) f'(O_{net\ l}) \quad (8)$$

Dimana:

$$f'(O_{net\ l}) = (1 - f(O_{net\ l}))f(O_{net\ l}) \quad (9)$$

- Setelah nilai error pada *hidden layer* kedua dan lapisan keluaran diperoleh selanjutnya dengan menghitung kesalahan yang ada pada *hidden layer* pertama dan *hidden layer* kedua.

$$\delta_k = \delta_{net\ k} f'(G_{net\ k}) \quad (10)$$

Dimana:

$$\delta_{net\ k} = \sum_{l=1}^m \delta_l V_{kl} \quad (11)$$

$$f'(G_{net\ k}) = (1 - f(G_{net\ k}))f(G_{net\ k}) \quad (12)$$

- Setelah nilai error pada *hidden layer* pertama dan *hidden layer* kedua diperoleh selanjutnya dengan menghitung kesalahan yang ada pada *input layer* dan *hidden layer* pertama.

$$\delta_j = \delta_{net\ j} f'(H_{net\ j}) \quad (13)$$

Di mana :

$$\delta_{net\ j} = \sum_{k=1}^m \delta_k U_{jk} \quad (14)$$

$$f'(H_{net\ j}) = (1 - f(H_{net\ j}))f(H_{net\ j}) \quad (15)$$

- Setelah nilai error setiap lapisan diketahui maka perubahan besar atau koreksi akan dilakukan sehingga bobot lama dapat dihitung.

$$\Delta T_{ij} = \alpha \delta_j I_i \quad (16)$$

$$\Delta U_{jk} = \alpha \delta_k H_j \quad (17)$$

$$\Delta V_{kl} = \alpha \delta_l G_k \quad (18)$$

ΔT_{ij} , ΔU_{jk} , dan ΔV_{kl} perubahan yang ditambahkan pada bobot lama akan diperbarui. Dengan *learning rate*, δ_j adalah kesalahan yang terjadi antara

input layer dan *hidden layer* pertama, δ_k kesalahan antara *hidden layer* pertama dan *hidden layer* kedua, dan, δ_l kesalahan antara *hidden layer* kedua dan lapisan keluaran. I_i merupakan masukan asal dari neuron i ke neuron j . Sedangkan H_j merupakan hasil fungsi aktivasi *hidden layer* pertama, dan G_k merupakan hasil fungsi aktivasi *hidden layer* kedua.

7. Fase perubahan bobot

Setelah ΔT_{ij} , ΔU_{jk} , dan ΔV_{kl} hasil selanjutnya adalah memperbaiki bobot lama menjadi bobot baru.

$$T_{ij}(new) = T_{ij}(old) + \Delta T_{ij} \quad (19)$$

$$U_{jk}(new) = U_{jk}(old) + \Delta U_{jk} \quad (20)$$

$$V_{kl}(new) = V_{kl}(old) + \Delta V_{kl} \quad (21)$$

$T_{ij}(new)$ adalah bobot baru antara *input layer* dan *hidden layer* pertama yang dicari, sedangkan $T_{ij}(old)$ merupakan bobot lama yang akan diperbarui. $U_{jk}(new)$ merupakan bobot baru antara *hidden layer* pertama dan *hidden layer* kedua akan dicari sedangkan $U_{jk}(old)$ bobot lama yang akan diperbarui. $V_{kl}(new)$ adalah bobot baru antara *hidden layer* kedua dan lapisan keluaran yang akan dicari, sedangkan $V_{kl}(old)$ bobot lama yang akan diperbarui.

5.2 Implementasi

Pembuatan jaringan diprogram dengan dengan *Google Colab*. Model terdiri dari dua *hidden layer* dengan total 10 node pada *hidden layer* pertama dan 5 node pada *hidden layer* kedua. Pada proses evaluasi, optimalisasi jaringan diproses berdasarkan nilai MSE terkecil pada saat pembelajaran dengan memvariasikan setiap atribut menjadi variabel target dan menentukan jumlah node *hidden layer* pada strategi kedua Parameter pelatihan yang digunakan dapat dilihat pada Tabel 5.1.

Tabel 5.1 Parameter model

Tipe jaringan	BP-ANN
Fungsi aktivasi	ReLU
Optimizer	Adam
Persamaan	MSE
Input layer	7
<i>Hidden layer</i>	2 <i>Hidden layer</i>
Node <i>hidden layer</i>	(10,5)
Output layer	1
Learning rate	0.2

5.3 Uji coba

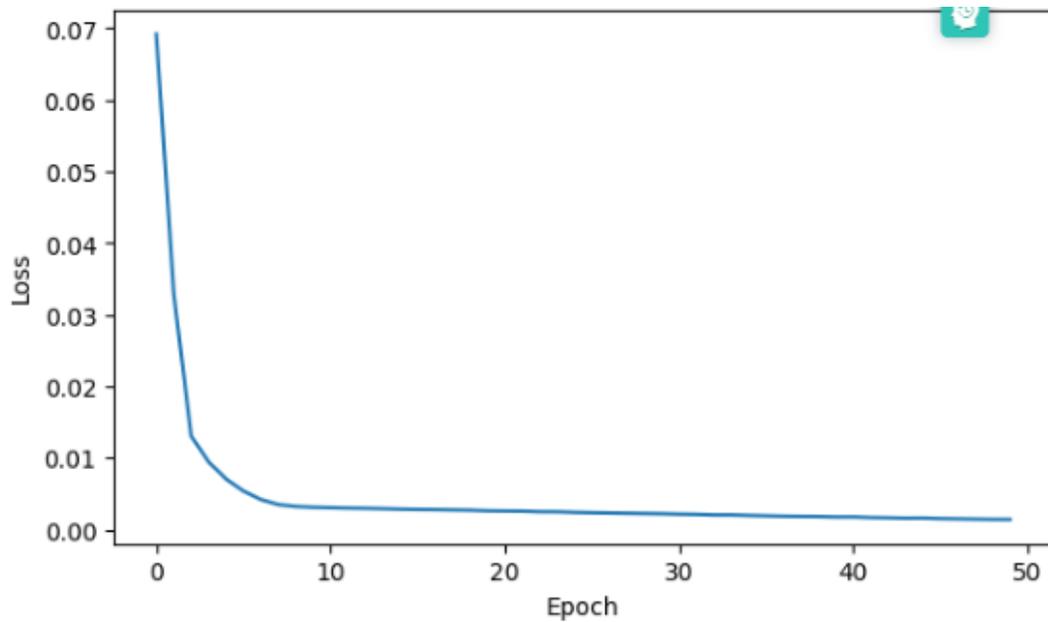
5.3.1 Pelatihan BP-2A

Hasil dari pelatihan BP-2A dengan penggunaan atribut *Open* (O) sebagai variabel target lengkap dapat dilihat pada Tabel 5.2.

Tabel 5.2 Proses pelatihan BP-2A

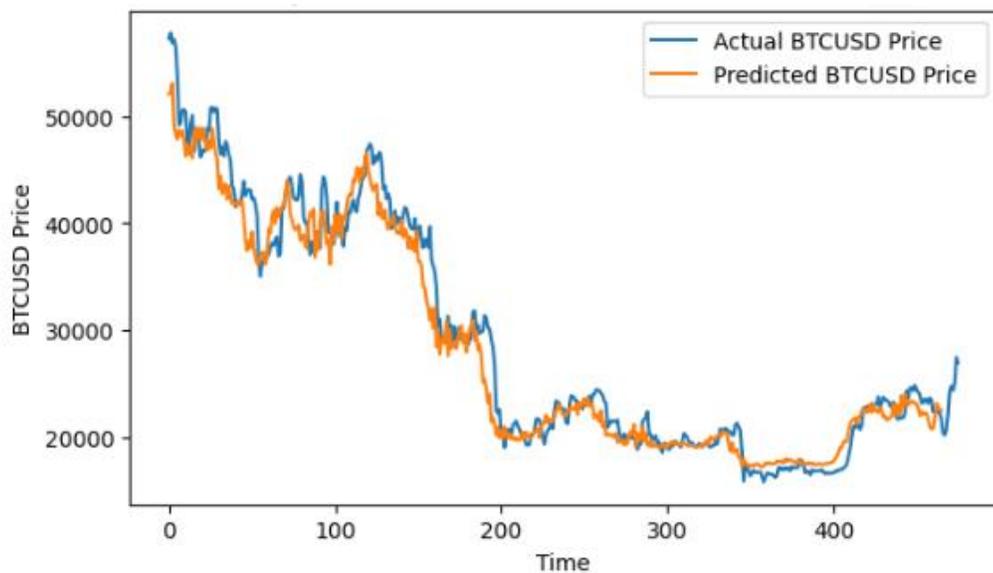
Epoch	Waktu konvergensi	MSE	Val_loss
1	179 <i>ms/step</i>	0.0692	0.0031
2	5 <i>ms/step</i>	0.0330	0.0030
3	5 <i>ms/step</i>	0.0131	0.0091
...
48	5 <i>ms/step</i>	0.0015	9.5636e ⁻⁰⁴
49	26 <i>ms/step</i>	0.0014	8.4229e ⁻⁰⁴
50	5 <i>ms/step</i>	0.0014	8.8644e ⁻⁰⁴

Tabel 5.2 menunjukkan bahwa proses pelatihan BP-2A dapat dilakukan selama 5 *ms/step* dengan nilai MSE sekitar 0.0014 dan tanda *validation_loss* sebesar 8.8644e⁻⁰⁴ atau sekitar 0.000886. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.2.



Gambar 5.2 Nilai loss pelatihan BP-2A

Grafik perbandingan antara output pelatihan BP-2A berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 5.3 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5.3 Perbandingan harga prediksi dengan data harga aktua BP-2A

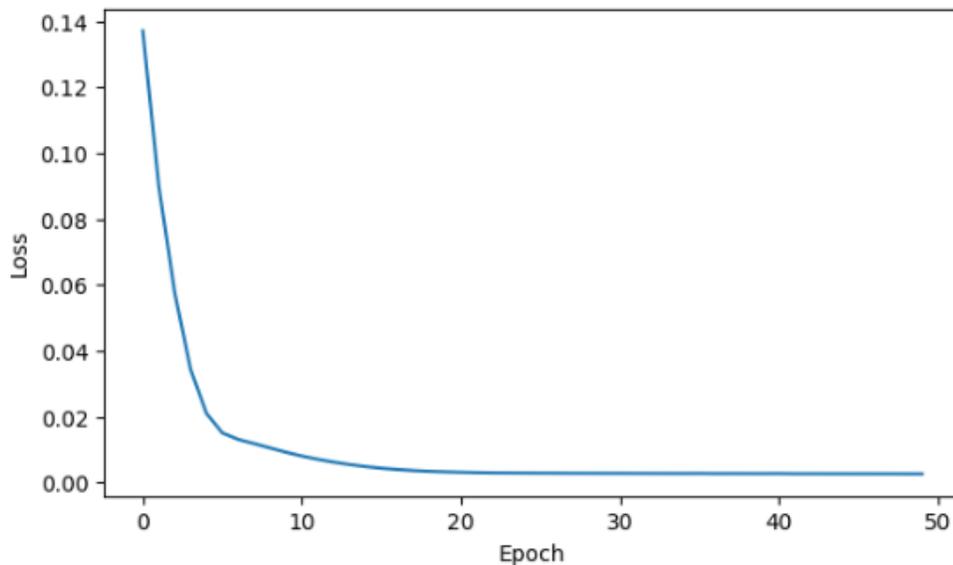
5.3.2 Pelatihan BP-2B

Hasil dari pelatihan BP-2B dengan menggunakan atribut *High* (H) sebagai variabel target lengkap dapat dilihat pada Tabel 5.3.

Tabel 5.3 Proses pelatihan BP-2B

Epoch	Waktu koergensi	MSE	Val_loss
1	174 <i>ms/step</i>	0.001371	0.0093
2	5 <i>ms/step</i>	0.0901	0.0042
3	5 <i>ms/step</i>	0.0577	0.0030
...
48	5 <i>ms/step</i>	0.0027	0.0019
49	6 <i>ms/step</i>	0.0027	0.0019
50	5 <i>ms/step</i>	0.0027	0.0019

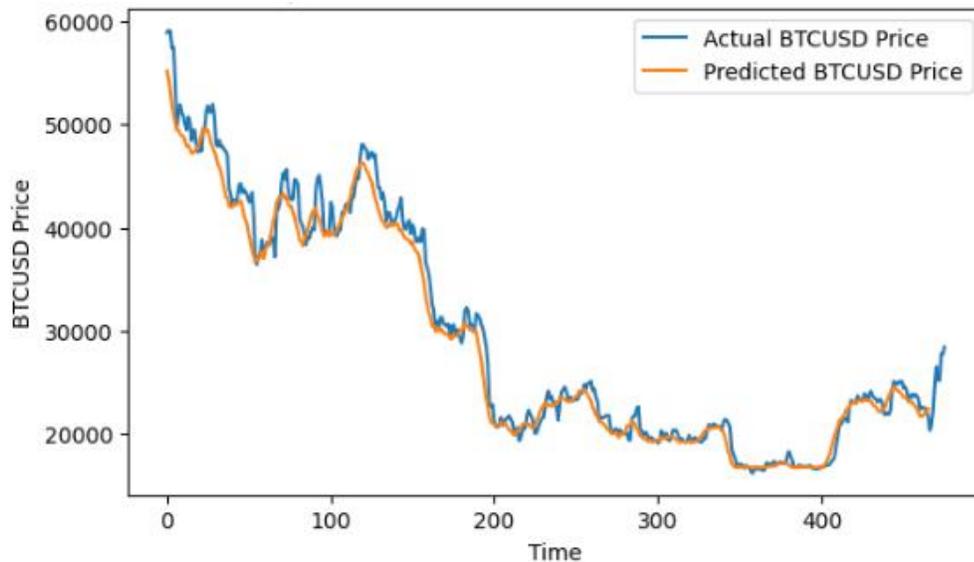
Tabel 5.3 menunjukkan bahwa proses pelatihan BP-2B dimungkinkan dilakukan selama 5 *ms/step* dengan nilai MSE sekitar 0.0027 dan tanda *validation_loss* sekitar 0.0019. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.4.



Gambar 5.4 Nilai loss pelatihan BP –2B

Grafik perbandingan antara output pelatihan BP-2B berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar

5.5 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5.5 Perbandingan harga prediksi dengan data harga aktual BP-2B

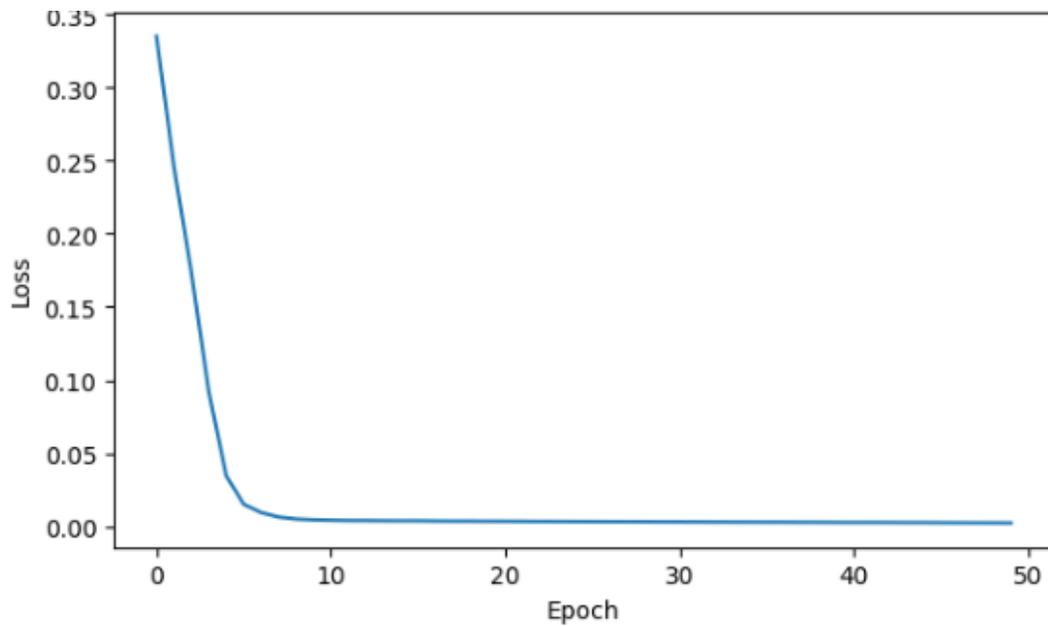
5.3.3 Pelatihan BP-2C

Hasil dari pelatihan BP-2C dengan menggunakan atribut *Low* (L) sebagai variabel target lengkap dapat dilihat pada Tabel 5.4.

Tabel 5.4 Proses pelatihan BP-2C

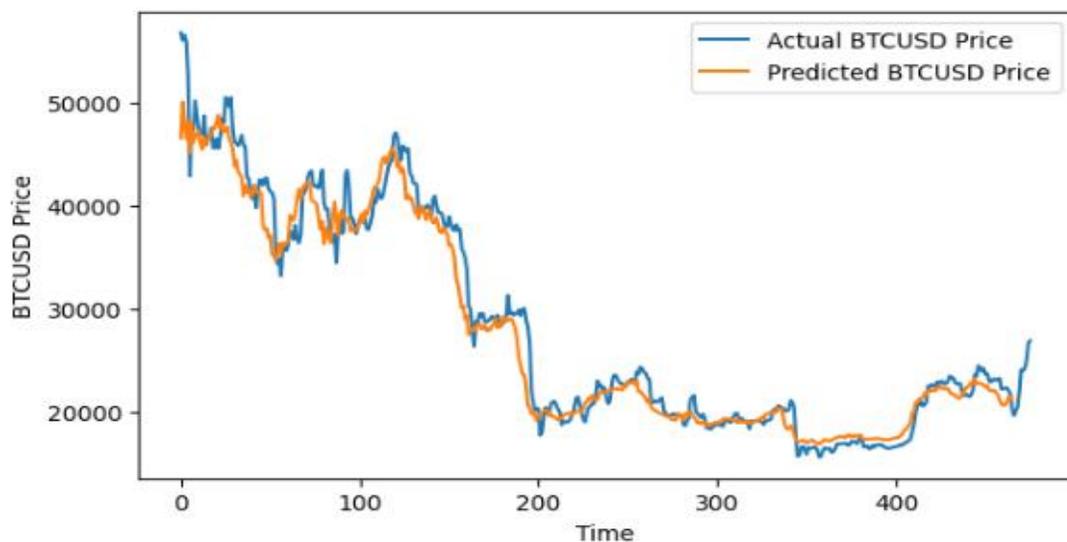
Epoch	Waktu konvergensi	MSE	Val_loss
1	78 ms/step	0.3354	0.0245
2	7 ms/step	0.2462	0.0115
3	9 ms/step	0.1736	0.0034
...
48	6 ms/step	0.0022	0.0014
49	7 ms/step	0.0022	0.0015
50	5 ms/step	0.0021	0.0014

Tabel 5.4 menunjukkan bahwa proses pelatihan BP-2C dapat dicapai dieksekusi selama 5 *ms/step* dengan nilai MSE sekitar 0.0021 dan tanda *validation_loss* sekitar 0.0014. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.6.



Gambar 5.6 Nilai loss pelatihan BP-2C

Grafik perbandingan antara output pelatihan BP-2C berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 5.7 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5.7 Perbandingan harga prediksi dengan data harga aktual BP-2C

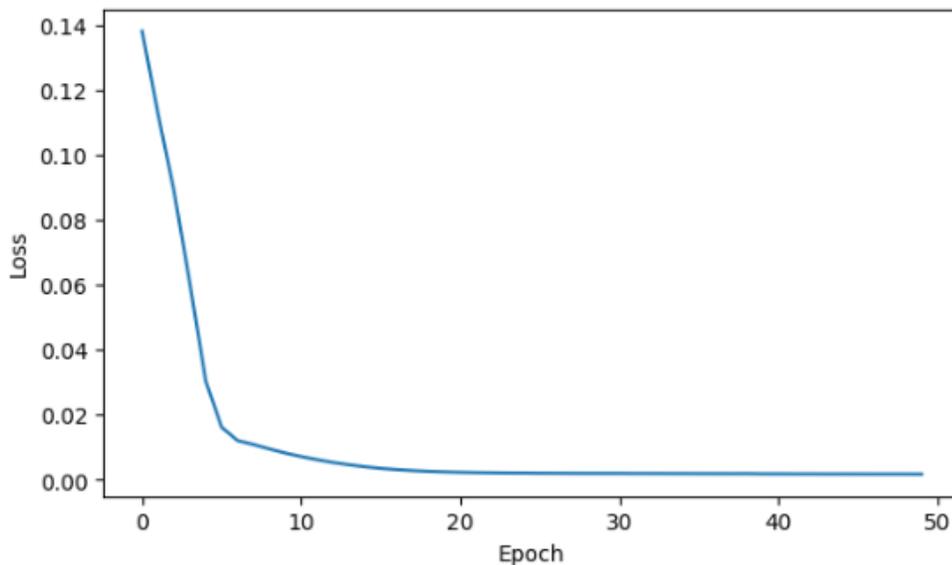
5.3.4 Pelatihan BP-2D

Hasil dari pelatihan BP-2D dengan penggunaan atribut *Close* (C) sebagai variabel target lengkap dapat dilihat pada Tabel 5.5.

Tabel 5.5 Proses pelatihan BP-2D

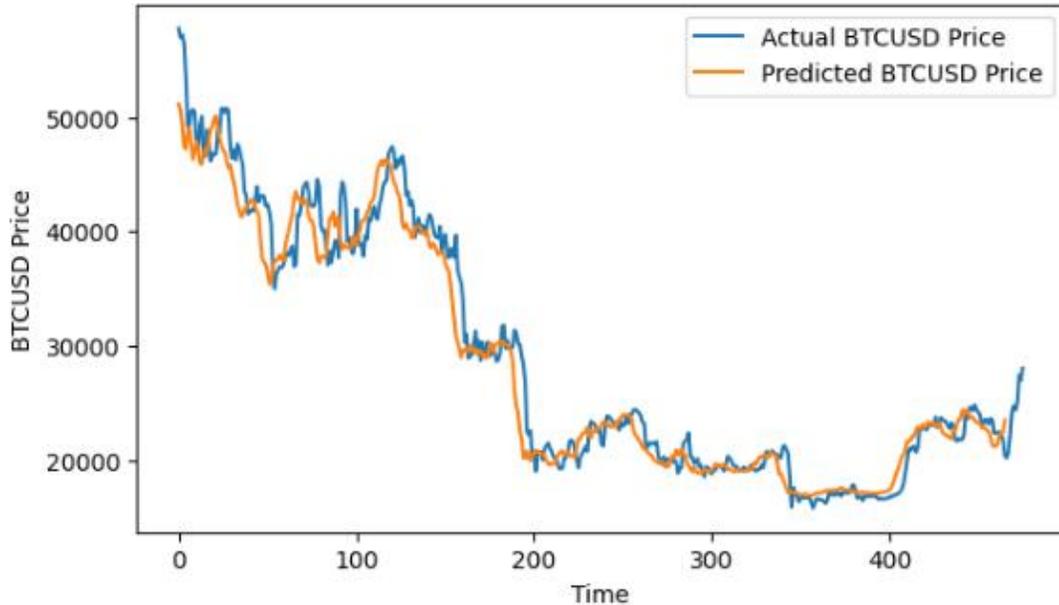
Epoch	Waktu konvergensi	MSE	Val_loss
1	43 <i>ms/step</i>	0,1382	0,0130
2	6 <i>ms/step</i>	0,0028	0,0080
3	6 <i>ms/step</i>	0,0027	0,0038
...
48	7 <i>ms/step</i>	0,0018	0,0011
49	7 <i>ms/step</i>	0,0018	0,0011
50	7 <i>ms/step</i>	0,0018	0,0011

Tabel 5.5 menunjukkan bahwa proses pelatihan BP-2D dimungkinkan dilakukan selama 7 *ms/step* dengan nilai MSE sekitar 0.0018 dan tanda *validasi_loss* sebesar sekitar 0.0011. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.8.



Gambar 5.8 Nilai loss pelatihan BP-2D

Grafik perbandingan antara output pelatihan BP-2D berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 5.9 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5.9 Perbandingan harga prediksi dengan data harga aktual BP– 2D

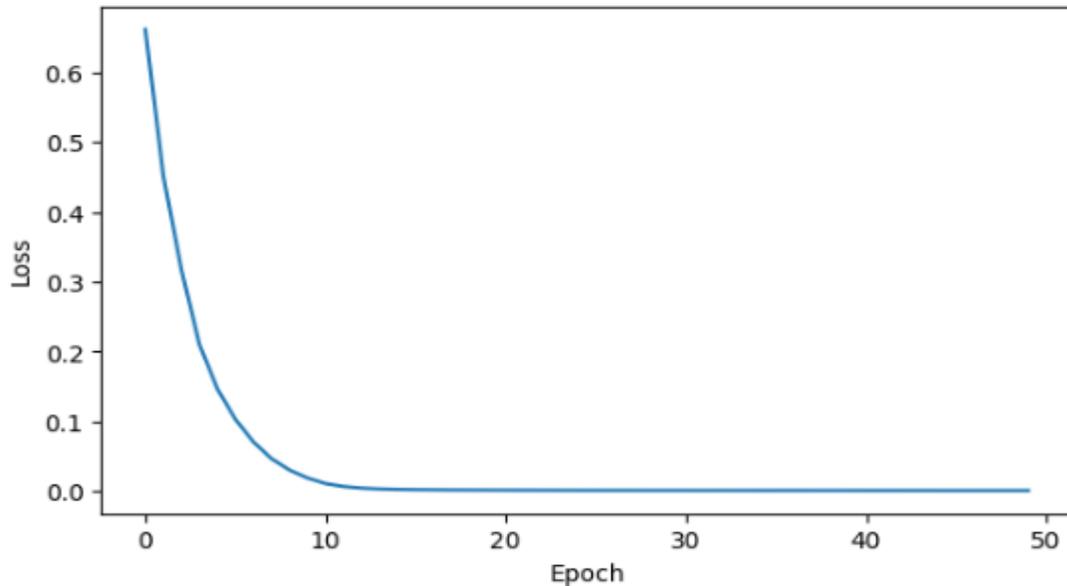
5.3.5 Pelatihan BP-2E

Hasil dari pelatihan BP-2E dengan menggunakan atribut *Adj Close* (AC) sebagai variabel target lengkap dapat dilihat pada Tabel 5.6.

Tabel 5.6 Proses pelatihan BP-2E

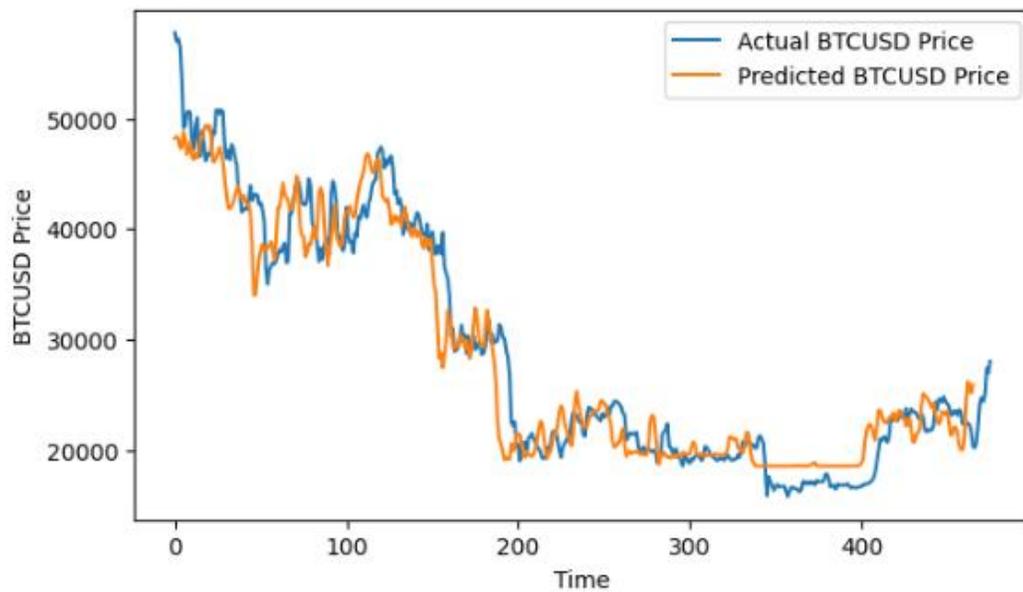
Epoch	Waktu konvergensi	MSE	Val_loss
1	74 ms/step	0.6618	0.0445
2	5 ms/step	0.4515	0.0215
3	6 ms/step	0.3175	0.0115
...
48	5 ms/step	0.0011	8.2755e ⁻⁰⁴
49	7 ms/step	0.0011	7.8116e ⁻⁰⁴
50	6 ms/step	0.0011	7.7499e ⁻⁰⁴

Tabel 5.6 menunjukkan bahwa proses pelatihan BP-2E dapat dilakukan selama 4 *ms/step* dengan nilai MSE berkisar 0.0011 dan nilai *validation_loss* sekitar $7.7499e^{-04}$ atau sekitar 0.000774. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.10.



Gambar 5.10 Nilai loss pelatihan BP-2E

Grafik perbandingan antara output pelatihan BP-2E berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 5.11 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5.11 Perbandingan harga prediksi dengan data harga aktual BP-2E

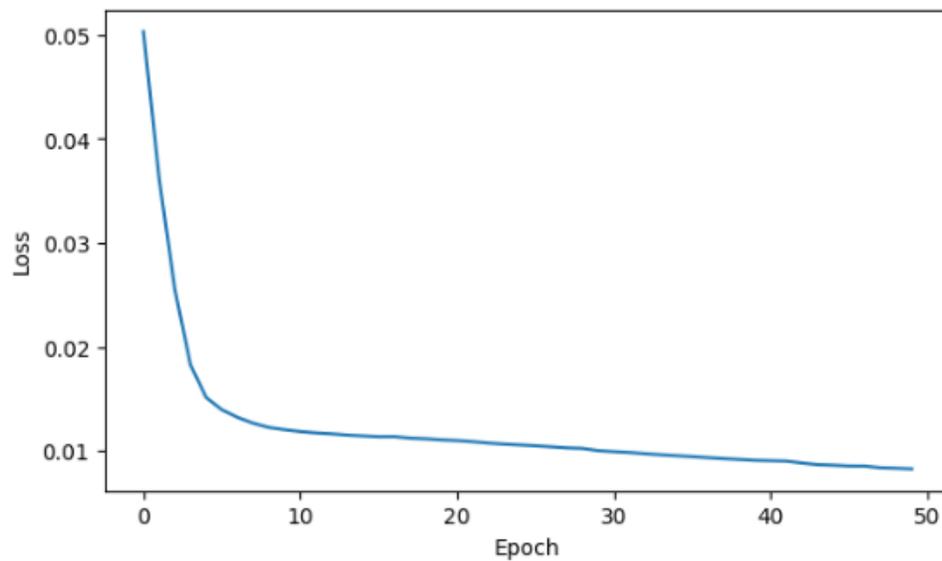
5.3.6 Pelatihan BP-2F

Hasil dari pelatihan BP-2F dengan menggunakan atribut *Volume* (V) sebagai variabel target secara lengkap dapat dilihat pada Tabel 5.7.

Tabel 5.7 Proses pelatihan BP-2F

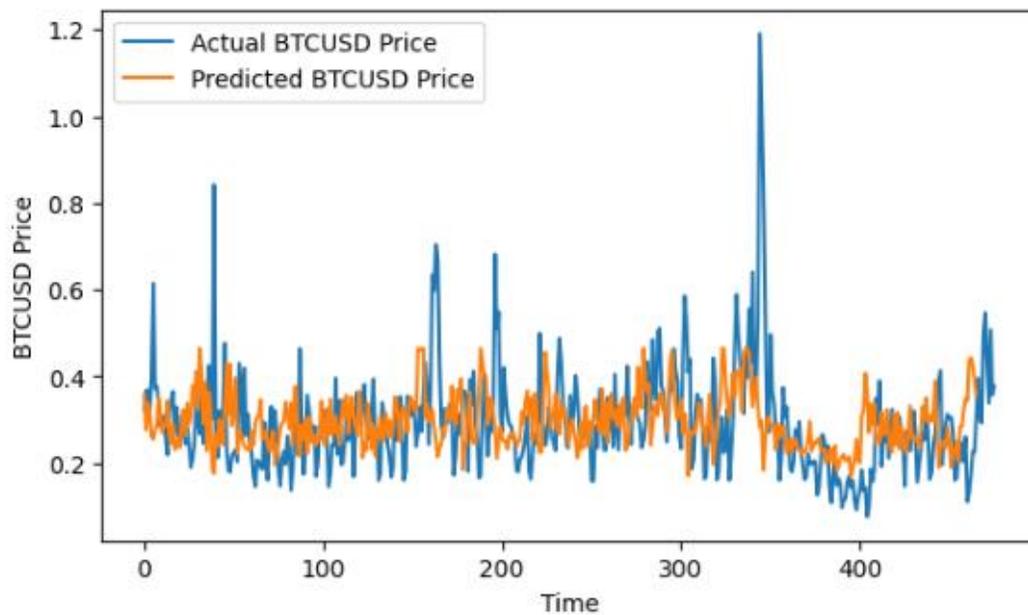
Epoch	Waktu kovergensi	MSE	Val_loss
1	137 <i>ms/step</i>	0.0503	0.0215
2	5 <i>ms/step</i>	0.0362	0.0140
3	6 <i>ms/step</i>	0.0256	0.0096
...
48	6 <i>ms/step</i>	0.00 84	0.0044
49	4 <i>ms/step</i>	0.00 83	0.0047
50	25 <i>ms/step</i>	0.00 83	0.0044

Tabel 5.7 menunjukkan bahwa proses pelatihan BP-2F dapat dicapai dieksekusi selama 25 *ms/step* dengan nilai MSE sekitar 0,083 dan nilai *validation_loss* sekitar 0,0044. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 5.12.



Gambar 5.12 Nilai loss pelatihan BP-2F

Grafik perbandingan antara output pelatihan BP-2F berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 5.13 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 5. Perbandingan harga prediksi dengan data harga aktual BP-2F

5.4 Hasil Prediksi

Setelah melakukan proses pelatihan pada masing-masing model, dilanjutkan dengan proses pengujian. Proses ini dilaksanakan untuk mengetahui performa terbaik dari arsitektur model dan untuk mengetahui pengaruh atribut terhadap prediksi harga *cryptocurrency* berdasarkan model ANN. Hasil proses pengujian disajikan pada Tabel 5.8.

Tabel 5.8 Hasil prediksi model BP-ANN pada strategi kedua

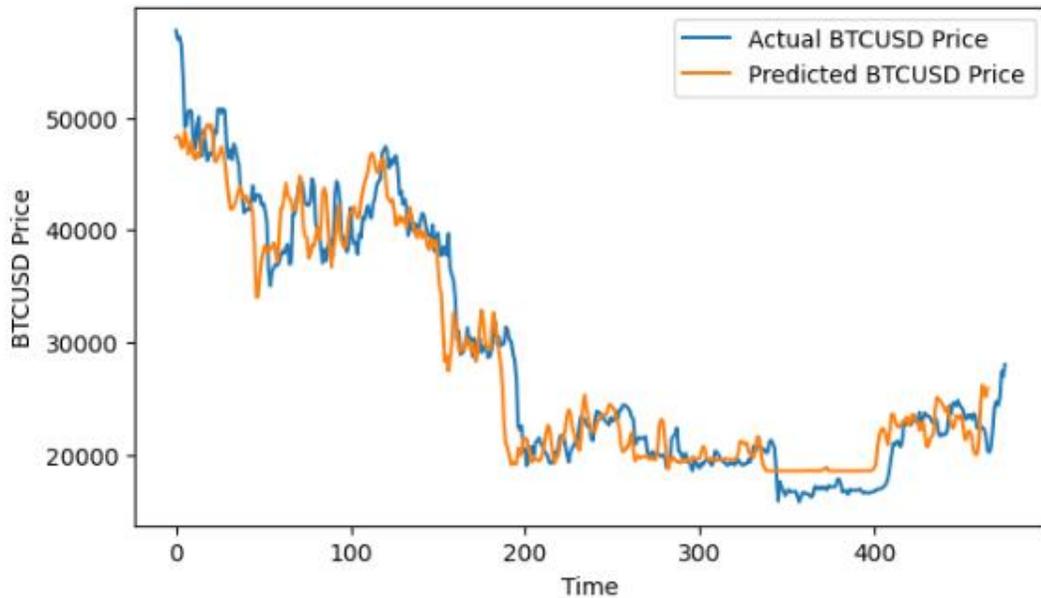
Pelatihan	Arsitektur	Waktu konvergensi	MSE
BP-2A	7-10-5-1	5 <i>ms/step</i>	8.8644e ⁻⁰⁴
BP-2B	7-10-5-1	5 <i>ms/step</i>	0.0019
BP-2C	7-10-5-1	5 <i>ms/step</i>	0.0014
BP-2D	7-10-5-1	7 <i>ms/step</i>	0.0011
BP-2E	7-10-5-1	6 <i>ms/step</i>	7.7499e⁻⁰⁴
BP-2F	7-10-5-1	25 <i>ms/step</i>	0.0044

Tabel 5.8 menunjukkan bahwa hasil prediksi model **BP-2E** menggunakan dua *hidden layer* (7-10-5-1) menunjukkan performa terbaik pada saat proses pelatihan dan pengujian model dengan nilai MSE sekitar 7.7499e⁻⁰⁴ atau sekitar 0.000774. Menurut Thomas *et al.*, (2017) menyatakan bahwa biasanya penggunaan dua *hidden layer* biasa lebih baik daripada satu *hidden layer* dalam jaringan model ANN. Namun berdasarkan hasil prediksi pada strategi pertama khususnya pada model BP – A1, hasilnya lebih baik dibandingkan dengan hasil prediksi pada strategi kedua (BP-2E) dengan nilai MSE sekitar 4.0431e⁻⁰⁴ atau sekitar 0.000404. Hal ini disebabkan oleh pengaruh atribut data sebagai variabel target pada proses pelatihan dan pengujian prediksi harga *cryptocurrency*.

5.5 Kesimpulan

Hasil prediksi harga *cryptocurrency* pada strategi pertama dengan satu *hidden layer* memiliki pola grafik yang mirip dibandingkan dengan nilai sebenarnya. Hal ini menunjukkan bahwa model ANN dengan algoritma *backpropagation* sangat efektif

untuk melakukan prediksi harga *cryptocurrency* yang ditandai dengan terutama pada proses pelatihan BP-2E.



Gambar 5.13 Grafik perbandingan model terbaik pada strategi kedua

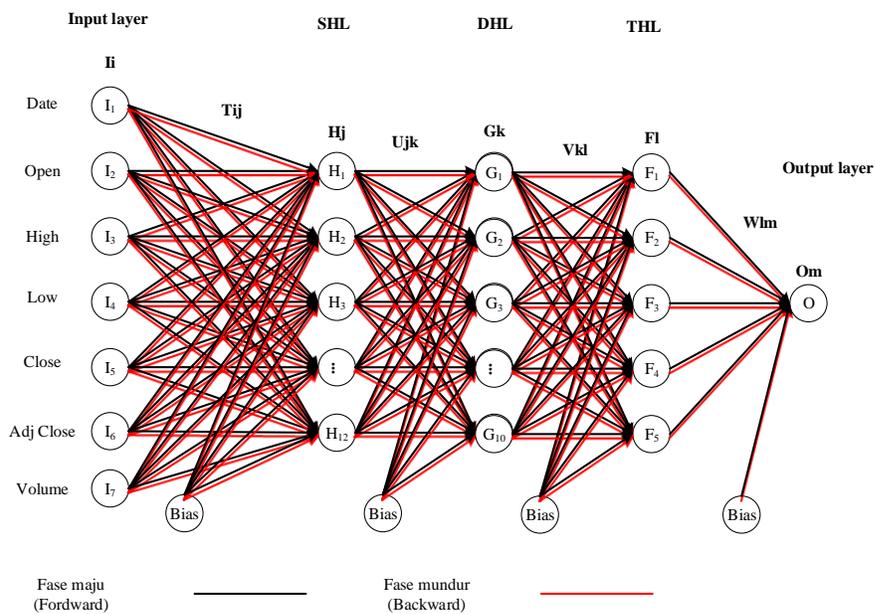
Berdasarkan uraian pada Tabel 5.8 dapat disimpulkan bahwa model BP-2E merupakan arsitektur model terbaik pada strategi kedua menggunakan dua *hidden layer* dengan nilai MSE sekitar $7.7499e^{-04}$ atau sekitar 0.000774. Namun arsitektur model ini tidak lebih baik dari arsitektur model pada strategi pertama dengan satu *hidden layer*. Hal ini disebabkan oleh pengaruh atribut data sebagai variabel target pada proses pelatihan dan pengujian prediksi harga *cryptocurrency*.

BAB VI

MODEL ANN TIGA *HIDDEN LAYER*

6.1 Desain

Perancangan strategi ketiga dengan tiga jaringan *hidden layer* pada algoritma *Backpropagation* ANN terdiri dari data masukan (I_i) berupa data harga *cryptocurrency*, nilai pembobotan antara *input layer* dan *hidden layer* pertama (T_{ij}), hasil keluaran berupa *hidden layer* pertama yang memiliki banyak node. ditentukan (H_j), nilai bobot antara *hidden layer* pertama dan *hidden layer* kedua (U_{jk}), hasil keluaran *hidden layer* kedua yang jumlah nodenya telah ditentukan (G_k), nilai bobot antara *hidden layer* kedua dan *hidden layer* ketiga (V_{kl}), hasil keluaran dari lapisan *hidden layer* ketiga yang jumlah nodenya telah ditentukan (F_l), nilai bobot antara *hidden layer* ketiga dengan lapisan keluaran (W_{lm}), dan nilai keluaran dalam bentuk harga *cryptocurrency* (O_m). Lebih jelasnya dapat dilihat pada Gambar 6.1 dibawah ini:



Gambar 6.1 Desain jaringan model ANN dengan tiga *hidden layer*

Strategi ketiga yang digunakan untuk memprediksi harga *cryptocurrency* menggunakan tiga *hidden layer* (7-12-10-5-1) berdasarkan model ANN dengan algoritma *backpropagation*. Langkah-langkah perhitungan strategi ketiga adalah sebagai berikut:

1. Mulai
2. Inisialisasi data pelatihan setelah dinormalisasi
3. Bobot inisialisasi dan jumlah nodenya .
4. Fase Propagasi Maju
 - Hitung sinyal dari setiap node pada *hidden layer* pertama (H_j). Pada fase informasi, informasi diberikan kepada variabel masukan (I_i) kemudian variabel ini akan meneruskan sinyal masukan ke seluruh *hidden layer*.

$$H_{net\ j} = T_{0j} + \sum_{i=1}^n I_i T_{ij} \quad (1)$$

Dengan i adalah node ke- i ($i = 1, 2, 3, \dots, n$) pada *input layer* dan j adalah node ke- j ($j = 1, 2, 3, \dots, p$) pada *hidden layer* pertama. I_i adalah nilai masukan pada node masukan i ke node tersembunyi j . T_{0j} adalah bias pada *input layer* dan T_{ij} adalah bobot pada node masukan i yang menuju ke neuron j .

- Semua keluaran pada *hidden layer* pertama dihitung menggunakan ReLU. Hasilnya akan digunakan oleh node-node pada *hidden layer* pertama dan kemudian masuk ke *hidden layer* kedua (G_k).

$$H_j = f(H_{net\ j}) = \max(0, H_{net\ j}) \quad (2)$$

Dengan maks sebagai tanda maksimum antara 0 dan $H_{net\ j}$. Hasil dari perhitungan $f(H_{net\ j})$ adalah nilai aktivasi pada neuron j yang tersembunyi yang kemudian dikirimkan ke seluruh neuron keluaran.

- Selanjutnya, hitung sinyal dari setiap detik node *hidden layer* (G_k). Pada fase ini, informasi diberikan pada variabel masukan (H_j) selanjutnya, variabel ini akan meneruskan sinyal masukan ke seluruh *hidden layer*.

$$G_{net\ k} = U_{0k} + \sum_{j=1}^n H_j U_{jk} \quad (3)$$

Dengan i adalah node ke- i ($j = 1, 2, 3, \dots, n$) pada *input layer* dan k merupakan node ke- k ($k = 1, 2, 3, \dots, p$) pada *hidden layer* kedua. H_j adalah nilai masukan pada node masukan j ke node tersembunyi k . U_{0k} adalah bias pada *input layer* dan U_{jk} merupakan bobot pada node masukan j yang menuju ke neuron k .

- Semua keluaran pada *hidden layer* kedua dihitung menggunakan ReLU. Hasilnya akan digunakan oleh node-node pada *hidden layer* kedua yang kemudian masuk pada proses selanjutnya.

$$G_k = f(G_{net\ k}) = \max(0, G_{net\ k}) \quad (4)$$

Dengan maks sebagai tanda maksimum antara 0 dan $G_{net\ k}$. Hasil dari perhitungan $f(G_{net\ k})$ adalah nilai aktivasi pada neuron tersembunyi k yang kemudian dikirimkan ke seluruh node *hidden layer* ketiga.

- Selanjutnya, hitung sinyal dari setiap node *hidden layer* ketiga (F_l). Pada tahap informasi diberikan kepada variabel masukan (G_k) maka variabel ini akan meneruskan sinyal masukan ke seluruh *hidden layer*.

$$F_{net\ l} = V_{0l} + \sum_{k=1}^n G_k V_{kl} \quad (5)$$

Dengan i merupakan node ke- i ($k = 1, 2, 3, \dots, n$) pada *input layer* dan k merupakan node ke- i ($l = 1, 2, 3, \dots, p$) pada *hidden layer* kedua. G_k adalah nilai masukan pada node masukan k ke node tersembunyi l . Sedangkan V_{0l} adalah bias pada *input layer*, dan V_{kl} merupakan bobot pada node masukan k yang menuju ke neuron l .

- Semua keluaran pada *hidden layer* ketiga dihitung menggunakan ReLU. Hasilnya akan digunakan oleh node-node pada *hidden layer* ketiga yang kemudian masuk pada proses selanjutnya.

$$F_l = f(F_{net\ l}) = \max(0, F_{net\ l}) \quad (6)$$

Dengan maks sebagai tanda maksimum antara 0 dan $F_{net\ l}$. Hasil dari perhitungan $f(F_{net\ l})$ adalah nilai aktivasi neuron tersembunyi l yang kemudian dikirim ke seluruh neuron keluaran.

- Setelah diperoleh tanda pada setiap *hidden layer* ketiga selanjutnya dijumlahkan seluruh sinyal masuk ke -output ($F_l \dots F_n$) dengan bobotnya.

$$O_{net\ m} = W_{0m} + \sum_{l=1}^n F_l W_{lm} \quad (7)$$

$O_{net\ m}$ adalah nilai bias pada *hidden layer* dan F_l adalah hasil yang keluar dari *hidden layer* ketiga, dan W_{lm} adalah bobot pada node tersembunyi neuron keluaran m ($m= 1, 2, 3, \dots, n$).

- Dengan menggunakan fungsi Aktivasi ReLU Untuk menghitung sinyal keluaran , maka tepat diperoleh tanda yaitu :

$$O_m = f(O_{net\ m}) = \max(0, O_{net\ m}) \quad (8)$$

$O_{net\ m}$ merupakan hasil fungsi aktivasi yaitu penjumlahan bobot antara node *hidden layer* ketiga dan node keluaran.

5. Setelah dihasilkan nilai keluaran Kemudian dihitung selisihnya dengan nilai keluaran target menggunakan persamaan MSE.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (9)$$

Jika waktu konvergensi telah tercapai, maka proses akan terhenti. Sebaliknya jika waktu konvergensi belum tercapai, maka dilakukan proses *backpropagation* dengan memperbarui bobot.

6. Fase Propagasi Balik

- Lakukan perhitungan faktor kesalahan (δ_m) pada lapisan keluaran (O_m) yang menerima pola target (t_m) yang kemudian dikirimkan ke lapisan berikutnya yang digunakan untuk menghitung koreksi bobot dan bias antara *input layer* dan *hidden layer*.

$$\delta_m = (t_m - O_m) f'(O_{net\ m}) \quad (10)$$

Di mana :

$$f'(O_{net\ m}) = (1 - f(O_{net\ m}))f(O_{net\ m}) \quad (11)$$

- Setelah kesalahan pada *hidden layer* ketiga dan lapisan keluaran diperoleh selanjutnya dengan menghitung kesalahan yang ada pada *hidden layer* kedua dan *hidden layer* ketiga.

$$\delta_l = \delta_{net\ l} f'(F_{net\ l}) \quad (12)$$

Di mana :

$$\delta_{net\ l} = \sum_{m=1}^n \delta_m W_{lm} \quad (13)$$

$$f'(F_{net\ l}) = (1 - f(F_{net\ l}))f(F_{net\ l}) \quad (14)$$

- Setelah kesalahan pada *hidden layer* kedua dan *hidden layer* ketiga diperoleh selanjutnya dengan menghitung kesalahan yang ada _ pada *hidden layer* pertama dan *hidden layer* kedua.

$$\delta_k = \delta_{net\ k} f'(G_{net\ k}) \quad (15)$$

Di mana :

$$\delta_{net\ k} = \sum_{l=1}^m \delta_l V_{kl} \quad (16)$$

$$f'(G_{net\ k}) = (1 - f(G_{net\ k}))f(G_{net\ k}) \quad (17)$$

- Setelah error pada *hidden layer* pertama dan *hidden layer* kedua diperoleh selanjutnya dengan menghitung kesalahan yang ada pada *input layer* dan *hidden layer* pertama.

$$\delta_j = \delta_{net\ j} f'(H_{net\ j}) \quad (18)$$

Di mana:

$$\delta_{net\ j} = \sum_{k=1}^m \delta_k U_{jk} \quad (19)$$

$$f'(H_{net\ j}) = (1 - f(H_{net\ j}))f(H_{net\ j}) \quad (20)$$

- Setelah kesalahan setiap lapisan diketahui maka perubahan besar atau koreksi akan dilakukan sehingga bobot lama dapat dihitung.

$$\Delta T_{ij} = \alpha \delta_j I_i \quad (21)$$

$$\Delta U_{jk} = \alpha \delta_k H_j \quad (22)$$

$$\Delta V_{kl} = \alpha \delta_l G_k \quad (23)$$

$$\Delta W_{lm} = \alpha \delta_m F_l \quad (24)$$

ΔT_{ij} , ΔU_{jk} , ΔV_{kl} , dan ΔW_{lm} perubahan yang ditambahkan pada bobot lama akan diperbarui . Dengan pembelajaran kecepatan (learning rate), δ_j kesalahan yang terjadi antara *input layer* dan *hidden layer* pertama, kesalahan antara δ_k *hidden layer* pertama dan *hidden layer* kedua, δ_l kesalahan antara *hidden layer* kedua dan *hidden layer* ketiga, dan δ_m kesalahan antara *hidden layer* ketiga dan lapisan keluaran tersembunyi. I_i merupakan masukan asal

dari neuron i ke neuron j sedangkan H_j merupakan hasil fungsi aktivasi dari *hidden layer* pertama, G_k merupakan hasil fungsi aktivasi dari *hidden layer* kedua, dan F_l merupakan hasil fungsi aktivasi *hidden layer* ketiga.

7. Fase perubahan bobot

Setelah ΔT_{ij} , ΔU_{jk} , ΔV_{kl} , dan ΔW_{lm} hasil selanjutnya adalah memperbaiki bobot lama menjadi bobot baru.

$$T_{ij}(new) = T_{ij}(old) + \Delta T_{ij} \quad (25)$$

$$U_{jk}(new) = U_{jk}(old) + \Delta U_{jk} \quad (26)$$

$$V_{kl}(new) = V_{kl}(old) + \Delta V_{kl} \quad (27)$$

$$W_{lm}(new) = W_{lm}(old) + \Delta W_{lm} \quad (28)$$

$T_{ij}(new)$ adalah bobot baru antara *input layer* dan *hidden layer* yang akan dicari terlebih dahulu sedangkan $T_{ij}(old)$ merupakan bobot lama yang akan diperbarui.

$U_{jk}(new)$ apakah bobot baru antara *hidden layer* pertama dan *hidden layer* kedua akan dicari sedangkan $U_{jk}(old)$ bobot lama yang akan diperbarui.

$V_{kl}(new)$ adalah bobot baru antara *hidden layer* kedua dan *hidden layer* ketiga yang akan dicari sedangkan $V_{kl}(old)$ bobot lama yang akan diperbarui.

$W_{lm}(new)$ adalah bobot baru antara *hidden layer* ketiga dan lapisan keluaran sementara $W_{lm}(old)$ merupakan bobot lama yang akan diperbarui.

6.2 Implementasi

Pembuatan jaringan diprogram dengan dengan *Google Colab*. Model terdiri dari dua *hidden layer* dengan total 12 node pada *hidden layer* pertama, 10 node pada *hidden layer* kedua, dan 5 node pada *hidden layer* ketiga. Pada proses evaluasi, optimalisasi jaringan diproses berdasarkan nilai MSE terkecil pada saat pembelajaran dengan memvariasikan setiap atribut menjadi variabel target dan menentukan jumlah node *hidden layer* pada strategi ketiga. Parameter pelatihan yang digunakan dapat dilihat pada Tabel 6.1.

Tabel 6.1 Parameter model

Tipe jaringan	BP-ANN
Fungsi aktivasi	ReLU
Optimizer	Adam
Persamaan	MSE
Input layer	7
<i>Hidden layer</i>	3 <i>hidden layer</i>
<i>Node hidden layer</i>	(12,10,5)
Output layer	1
Learning rate	0.2

6.3 Uji coba

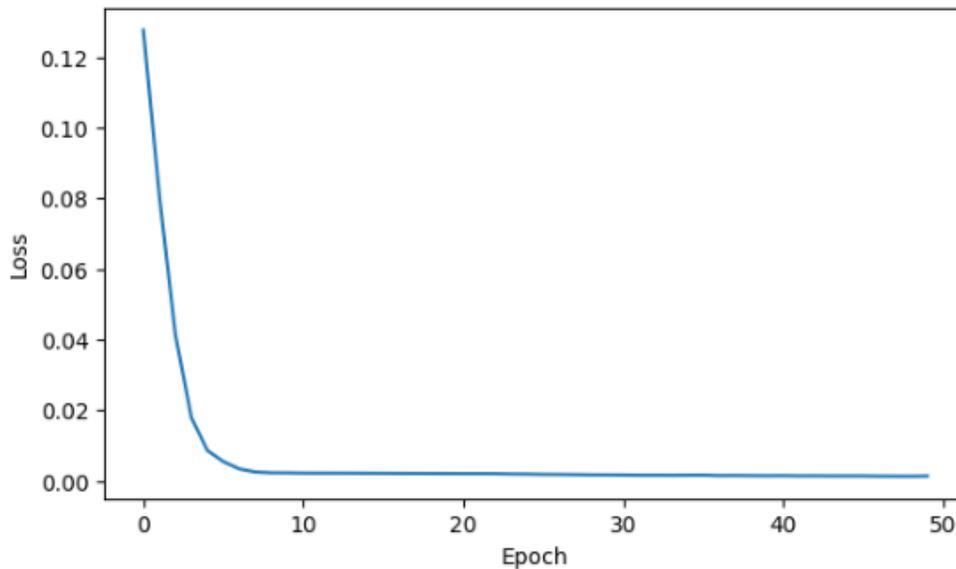
6.3.1 Pelatihan BP-3A

Hasil dari pelatihan BP-3A dengan penggunaan atribut *Open* (O) sebagai variabel target lengkap dapat dilihat pada Tabel 6.2.

Tabel 6.2 Proses pelatihan BP-3A

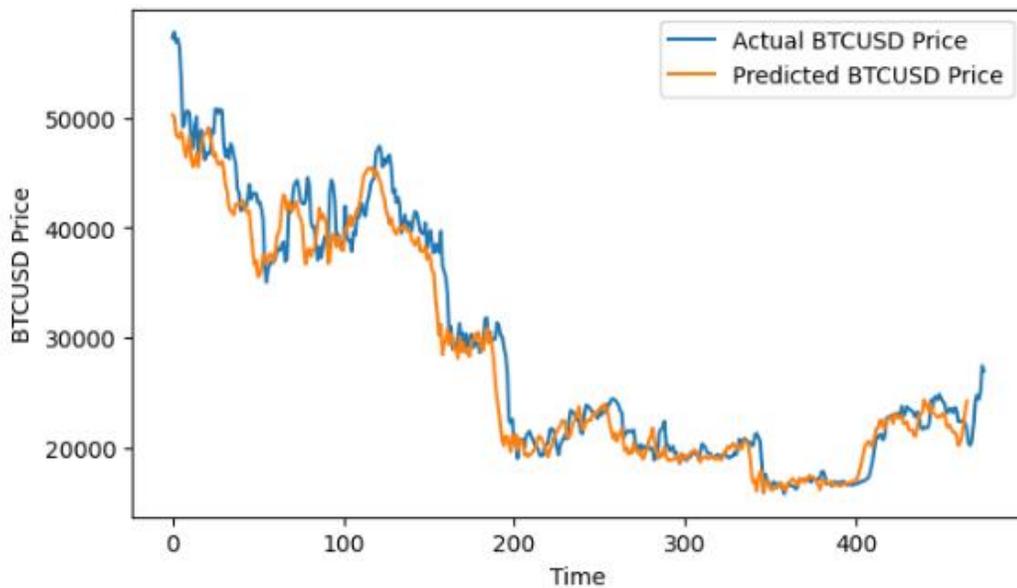
Epoch	Waktu konvergensi	MSE	Val_loss
1	52 <i>ms/step</i>	0.1276	0.0078
2	3 <i>ms/step</i>	0.0807	0.0025
3	3 <i>ms/step</i>	0.0414	0.0033
...
48	3 <i>ms/step</i>	0.0014	7.0635e ⁻⁰⁴
49	4 <i>ms/step</i>	0.0013	8.2232e ⁻⁰⁴
50	3 <i>ms/step</i>	0.0014	8.7154e ⁻⁰⁴

Tabel 6.2 menunjukkan bahwa proses pelatihan BP-3A dapat dilakukan selama 3 *ms/step* dengan nilai MSE berkisar 0.0014 dan nilai *validation_loss* sebesar 8.7154e⁻⁰⁴ atau sekitar 0.000871. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.2.



Gambar 6.2 Nilai loss pelatihan BP-3A

Grafik perbandingan antara output pelatihan BP-3A berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 6.3 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.3 Perbandingan harga prediksi dengan data harga aktual BP-3A

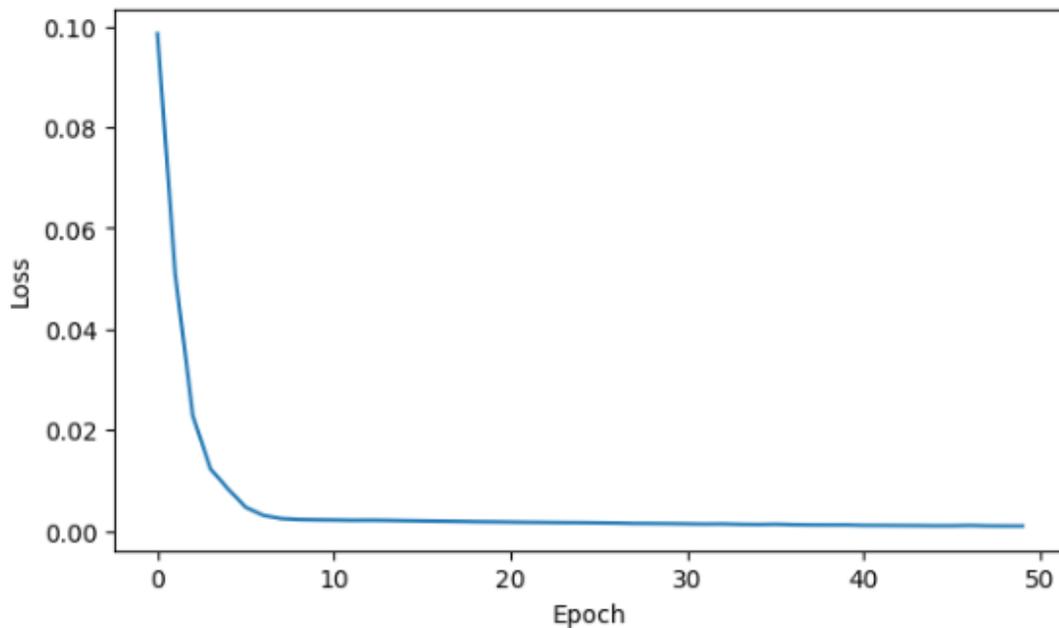
6.3.2 Pelatihan BP-3B

Hasil dari pelatihan BP-3B dengan menggunakan atribut *High* (H) sebagai variabel sasaran lengkap dapat dilihat pada Tabel 6.3.

Tabel 4.3 Proses pelatihan BP-3B

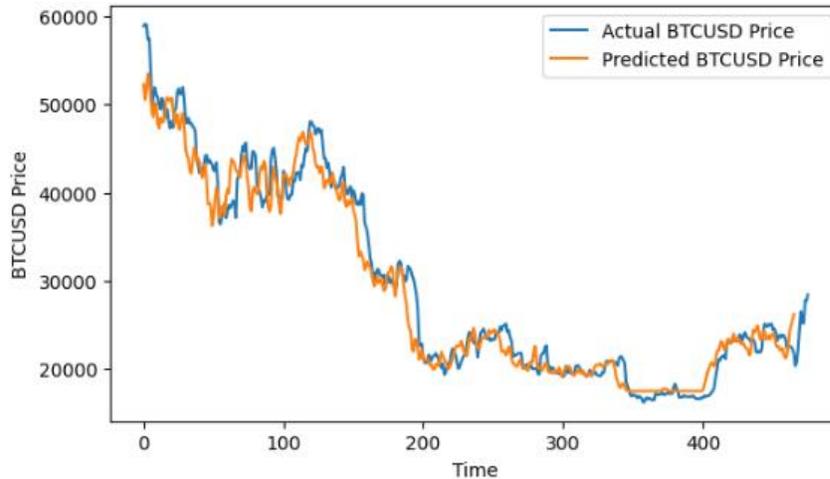
Epoch	Waktu kovergensi	MSE	Val_loss
1	26 <i>ms/step</i>	0.0986	0.0048
2	10 <i>ms/step</i>	0.0511	0.0027
3	8 <i>ms/step</i>	0.0229	0.0075
...
48	7 <i>ms/step</i>	0.0011	6.8644e ⁻⁰⁴
49	7 <i>ms/step</i>	0.0010	7.0800e ⁻⁰⁴
50	26 <i>ms/step</i>	0.0986	0.0048

Tabel 6.3 menunjukkan bahwa proses pelatihan BP-3B dapat dicapai dieksekusi selama 5 *ms/step* dengan nilai MSE berkisar 0.0010 dan nilai *validasi_loss* sebesar 6.3363e⁻⁰⁴ atau sekitar 0.000633. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.4.



Gambar 6.4 Nilai loss pelatihan BP-3B

Grafik perbandingan antara output pelatihan BP-3B berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 6.5 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.5 Perbandingan harga prediksi dengan data harga aktual BP-3B

6.3.3 Pelatihan BP-3C

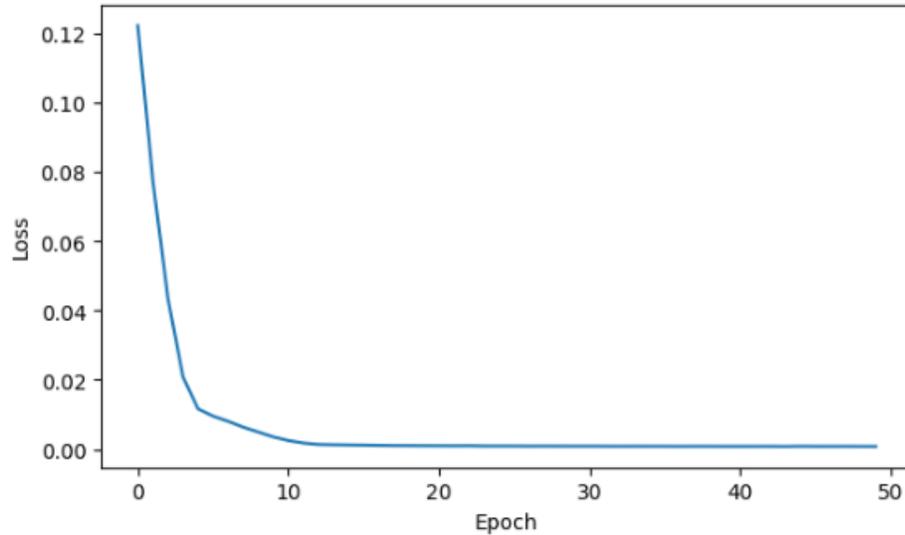
Hasil dari pelatihan BP-3C dengan menggunakan atribut *Low* (L) sebagai variabel target dapat dilihat pada Tabel 6.4.

Tabel 6.4 Proses pelatihan BP-3C

Epoch	Waktu kovergensi	MSE	Val_loss
1	56 ms/step	0.1224	0.0080
2	6 ms/step	0.0776	0.0026
3	6 ms/step	0.0435	0.0024
...
48	6 ms/step	8.1190e ⁻⁰⁴	3.2597e ⁻⁰⁴
49	6 ms/step	7.9329e ⁻⁰⁴	3.2726e ⁻⁰⁴
50	5 ms/step	7.7943e ⁻⁰⁴	3.6412e ⁻⁰⁴

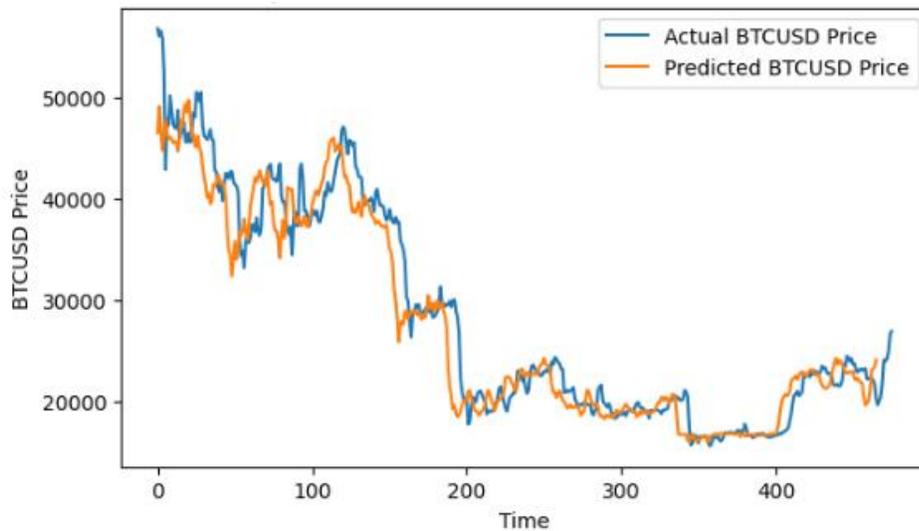
Tabel 6.4 menunjukkan bahwa proses pelatihan BP-3C dapat dicapai dieksekusi selama 5 ms/step dengan nilai MSE sebesar 7.7943e⁻⁰⁴ atau sekitar

0.000779 dan nilai *validation_loss* sebesar $3.6412e^{-04}$ atau sekitar 0.000364. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.6.



Gambar 6.6 Nilai loss pelatihan BP-3C

Grafik perbandingan antara output pelatihan BP-3C berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 6.7 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.7 Perbandingan harga prediksi dengan data harga aktual BP-3C

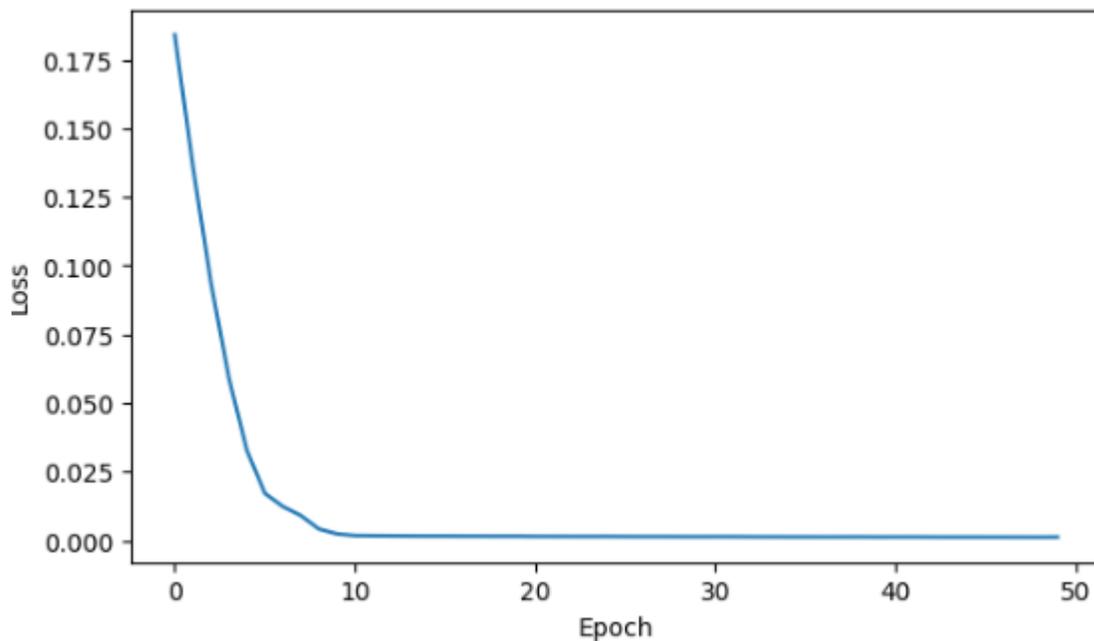
6.3.4 Pelatihan BP-3D

Hasil dari pelatihan BP-3D dengan menggunakan atribut *Close* (C) sebagai variabel target dapat dilihat pada Tabel 6.5.

Tabel 6.5 Proses pelatihan BP-3D

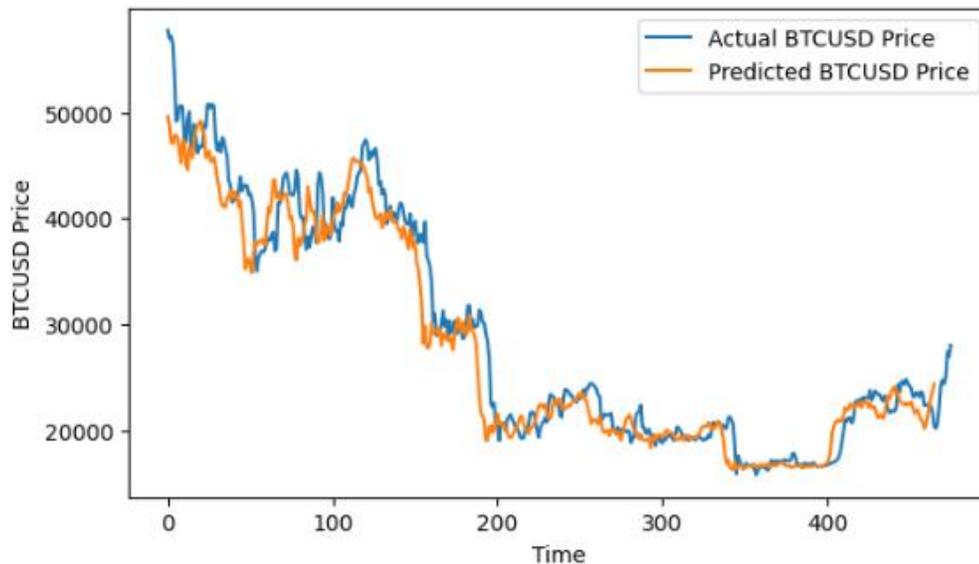
Epoch	Waktu konvergensi	MSE	Val_loss
1	58 <i>ms/step</i>	0,1841	0,0136
2	6 <i>ms/step</i>	0,1365	0,0069
3	5 <i>ms/step</i>	0,0094	0,0031
...
48	16 <i>ms/step</i>	0,0013	8.5015e ⁻⁰⁴
49	8 <i>ms/step</i>	0,0013	6.5548e ⁻⁰⁴
50	13 <i>ms/step</i>	0,0013	9.0289e ⁻⁰⁴

Tabel 6.5 menunjukkan bahwa proses pelatihan BP-3D dimungkinkan dilakukan selama 13 *ms/step* dengan nilai MSE sekitar 0.0013 dan nilai *validation_loss* sebesar 9.0289e⁻⁰⁴ atau sekitar 0.0009. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.8.



Gambar 6.8 Nilai loss pelatihan BP-3D

Grafik perbandingan antara output pelatihan BP-3D berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 6.9 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.9 Perbandingan harga prediksi dengan harga aktual BP-3D

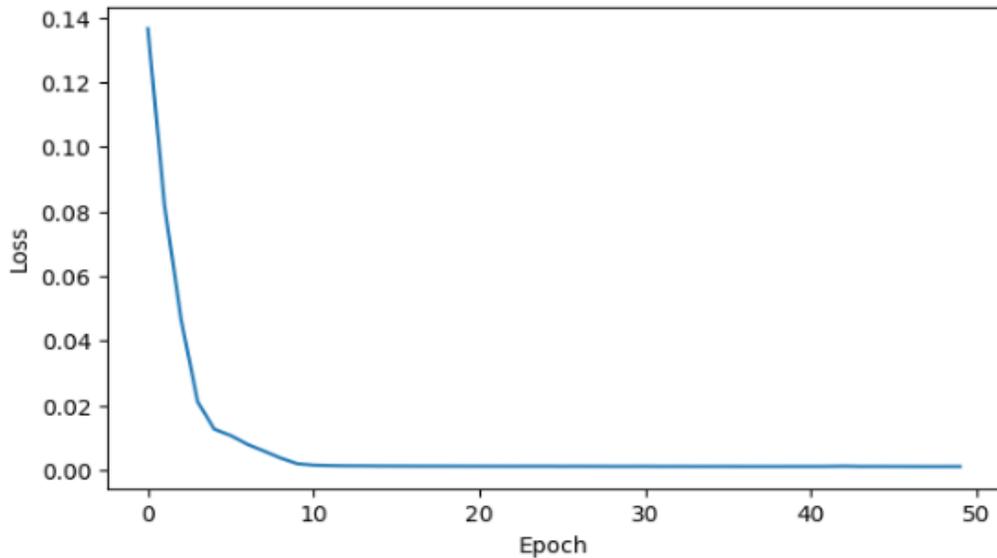
6.3.5 Pelatihan BP-3E

Hasil pelatihan BP-3E dengan menggunakan atribut *Adj Close* (AC) sebagai variabel target dapat dilihat pada Tabel 6.6.

Tabel 6.6 Proses pelatihan BP-3E

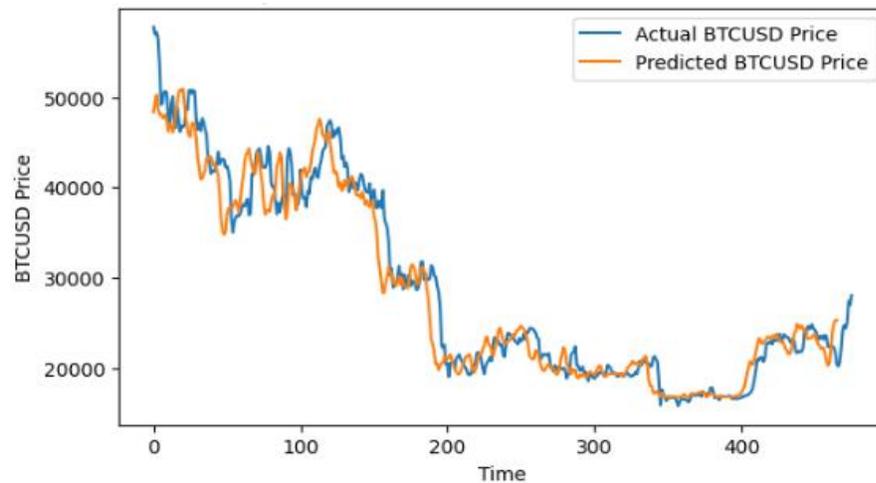
Epoch	Waktu konvergensi	MSE	Val_loss
1	158 <i>ms/step</i>	0,1868	0,0014
2	6 <i>ms/step</i>	0,1237	0,0082
3	6 <i>ms/step</i>	0,0963	0,0044
...
48	6 <i>ms/step</i>	0,0011	6.3413e ⁻⁰⁴
49	6 <i>ms/step</i>	0,0011	6.7318e ⁻⁰⁴
50	6 <i>ms/step</i>	0,0011	5.9736e ⁻⁰⁴

Tabel 6.6 menunjukkan bahwa proses pelatihan BP-3E dapat dicapai dieksekusi selama 6 *ms/step* dengan nilai MSE sekitar 0.0011 dan nilai *validation_loss* sebesar $5.9736e^{-04}$ atau sekitar 0.000597. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.10.



Gambar 6.10 Nilai loss pelatihan BP-3E

Grafik perbandingan antara output pelatihan BP-3E berupa prediksi harga *cryptocurrency* dengan target berupa harga aktual *cryptocurrency* pada Gambar 6.11 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.11 Perbandingan harga prediksi dengan harga aktual BP-3E

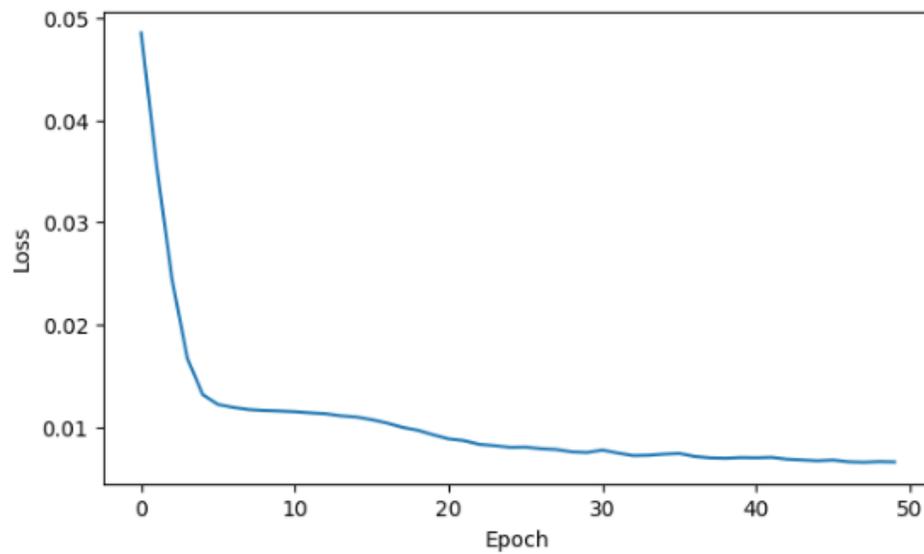
6.3.6 Pelatihan BP-3F

Hasil dari pelatihan BP-3F dengan menggunakan atribut *Volume* (V) sebagai variabel target secara lengkap dapat dilihat pada Tabel 6.7.

Tabel 6.7 Proses pelatihan BP-3F

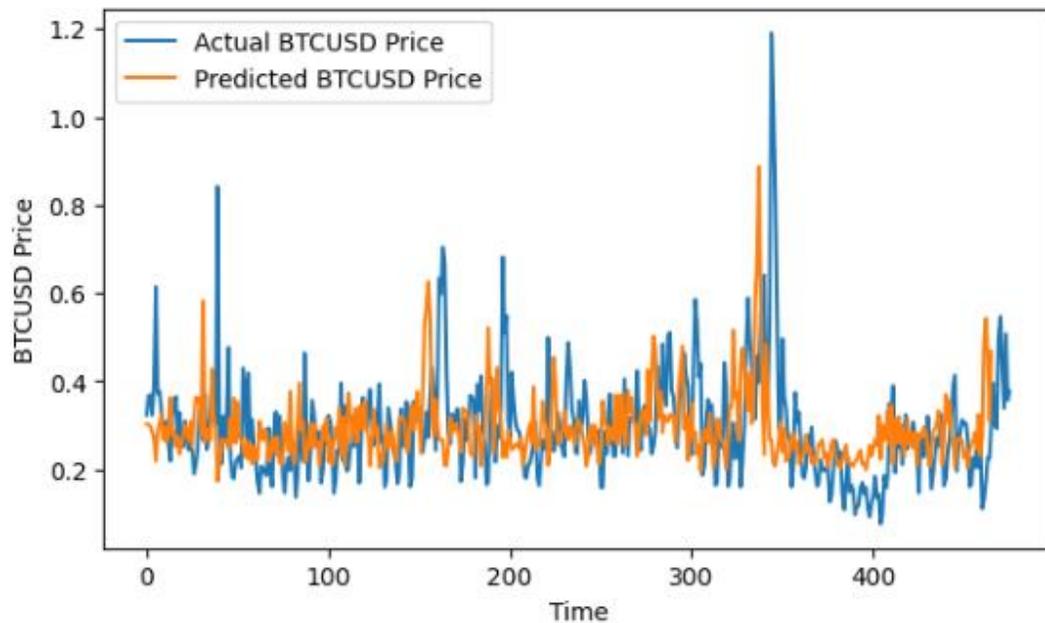
Epoch	Waktu konvergensi	MSE	Val_loss
1	81 <i>ms/step</i>	0,0485	0,0208
2	6 <i>ms/step</i>	0,0356	0,0131
3	6 <i>ms/step</i>	0,0245	0,0085
...
48	4 <i>ms/step</i>	0,0065	0,0054
49	4 <i>ms/step</i>	0,0066	0,0058
50	4 <i>ms/step</i>	0,0066	0,0051

Tabel 6.7 menunjukkan bahwa proses pelatihan BP-3F dapat dilakukan dalam waktu 4 *ms/step* dengan nilai MSE sekitar 0.0066 dan nilai *validation_loss* sebesar sekitar 0.0051. Grafik hasil *plotting* pada proses tersebut dapat dilihat pada Gambar 6.12.



Gambar 6.12 Nilai loss pelatihan BP-3F

Grafik perbandingan antara output pelatihan BP-3F berupa prediksi harga *cryptocurrency* dengan target berupa data harga *cryptocurrency* aktual pada Gambar 6.13 memiliki pola grafik yang mirip, dengan kata lain model yang dibangun dapat memprediksi harga *cryptocurrency* dengan baik.



Gambar 6.13 Perbandingan harga prediksi dengan data harga aktual BP-3F

6.4 Hasil Prediksi

Setelah melakukan proses pelatihan pada masing-masing model, dilanjutkan dengan proses pengujian. Proses ini dilaksanakan untuk mengetahui performa terbaik dari arsitektur model dan untuk mengetahui pengaruh atribut terhadap prediksi harga *cryptocurrency* berdasarkan model ANN. Hasil proses pengujian disajikan pada Tabel 6.8.

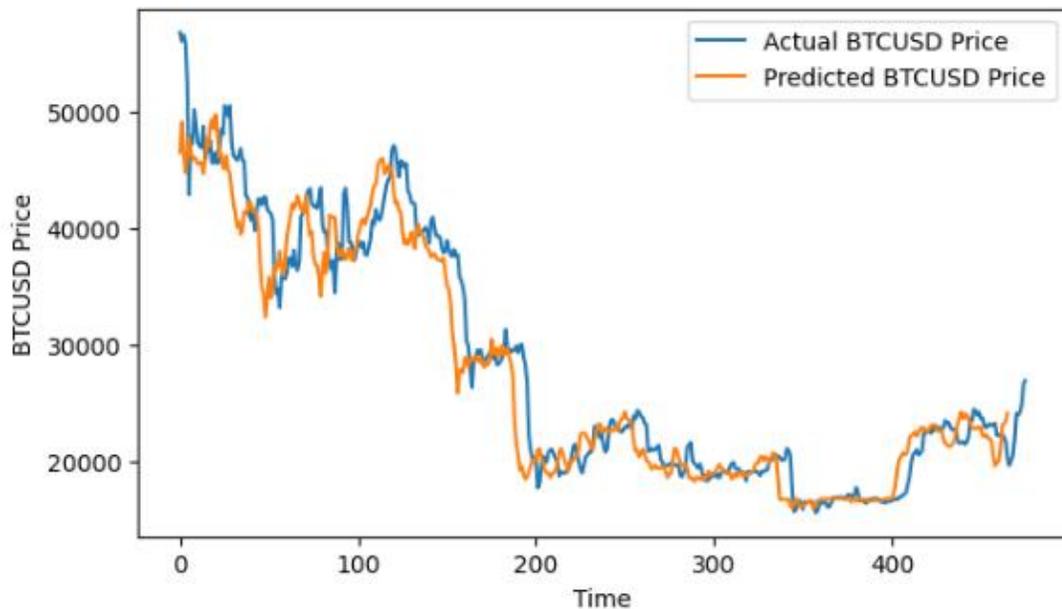
Tabel 6.8 Hasil prediksi model BP-ANN pada strategi ketiga

Pelatihan	Arsitektur	Waktu	MSE
BP-3A	7-12-10-5-1	3 <i>ms/step</i>	8.7154e ⁻⁰⁴
BP-3B	7-12-10-5-1	5 <i>ms/step</i>	6.3363e ⁻⁰⁴
BP-3C	7-12-10-5-1	5 <i>ms/step</i>	3.6412e⁻⁰⁴
BP-3D	7-12-10-5-1	13 <i>ms/step</i>	9.0289e ⁻⁰⁴
BP-3E	7-12-10-5-1	6 <i>ms/step</i>	5.9736e ⁻⁰⁴
BP-3F	7-12-10-5-1	4 <i>ms/step</i>	0,0051

Tabel 6.8 menunjukkan bahwa hasil prediksi model **BP-3C** menggunakan tiga *hidden layer* (7-12-10-5-1) menunjukkan hasil terbaik pada saat proses pelatihan dan proses pengujian model dengan memperoleh nilai MSE sekitar 3.6412e⁻⁰⁴ atau sekitar 0,000364. Hasil tersebut menunjukkan bahwa model BP-3C pada strategi ketiga dengan tiga *hidden layer* merupakan model dengan performa terbaik dibandingkan model pada strategi pertama dengan satu *hidden layer* (BP-1A) dan strategi kedua dengan dua *hidden layer* (BP-2E). Hal ini sejalan dengan temuan penelitian Xiao *et al*, (2017) yang menunjukkan bahwa penggunaan *multihidden layer* memperoleh hasil yang memuaskan berdasarkan performa dan nilai MSE dibandingkan dengan penggunaan satu dan dua *hidden layer* pada model yang di usulkan.

6.5 Kesimpulan

Hasil prediksi harga *cryptocurrency* pada strategi pertama dengan satu *hidden layer* memiliki pola grafik yang mirip dibandingkan dengan nilai sebenarnya. Hal ini menunjukkan bahwa model ANN dengan algoritma *backpropagation* sangat efektif untuk melakukan prediksi harga *cryptocurrency* yang ditandai dengan terutama pada proses pelatihan BP-3C.



Gambar 6.14 Grafik perbandingan model terbaik pada strategi ketiga

Berdasarkan uraian pada Tabel 6.8 dapat disimpulkan bahwa model BP-3C pada strategi ketiga dengan tiga *hidden layer* merupakan arsitektur model terbaik berdasarkan pengaruh atribut dan tingkat kinerja dibandingkan dengan arsitektur model pada strategi pertama, dengan satu *hidden layer* (BP-1A) dan strategi kedua dengan dua *hidden layer* (BP-2E).

BAB VII

PEMBAHASAN

Kinerja arsitektur model ANN menggunakan algoritma *backpropagation* pada strategi pertama menunjukkan kinerja yang lebih baik dibandingkan dengan arsitektur pada strategi kedua. Namun kedua arsitektur tersebut memerlukan waktu yang sama untuk mencapai konvergensi. Hal ini berbeda dengan arsitektur pada strategi ketiga yang memerlukan waktu lebih cepat dibandingkan dengan arsitektur pada strategi pertama dan kedua. Penentuan atribut sebagai variabel target pada setiap arsitektur model sangat mempengaruhi proses penghitungan prediksi harga *cryptocurrency* baik pada proses pelatihan maupun pengujian.

Jumlah node pada setiap *hidden layer* bukan satu-satunya faktor yang mempengaruhi kinerja model ANN dengan algoritma *backpropagation*. Namun, jumlah *hidden layer* dalam model mempengaruhi pengulangan pada saat program berjalan. Kemudian, pemrosesan prediksi dilakukan dalam waktu konvergensi lebih cepat tercapai dengan menggunakan *hidden layer* yang lebih banyak. Selain itu, penentuan atribut sebagai variabel target sangat mempengaruhi proses penghitungan prediksi harga *cryptocurrency*. Sintesisnya adalah penentuan jumlah *hidden layer* dan penentuan atribut sebagai variabel target merupakan faktor utama yang mempengaruhi kinerja model. Dilihat dari waktu konvergensinya, strategi pertama dan strategi kedua memerlukan waktu yang sama. Sedangkan arsitektur pada strategi ketiga dengan tiga *hidden layer* membutuhkan waktu lebih cepat dengan kecepatan pemrosesan sekitar 5 ms/step dibandingkan dengan arsitektur kedua dengan kecepatan pemrosesan sekitar 6 ms/step .

Tabel 7.1 Waktu konvergensi dan hasil pengujian MSE

No	SHL		DHL		THL	
	Waktu konvergensi	Nilai MSE	Waktu konvergensi	Nilai MSE	Waktu konvergensi	Nilai MSE
1	6 ms/step	4.0431e⁻⁰⁴	5 ms/step	8.8644e ⁻⁰⁴	3 ms/step	8.7154e ⁻⁰⁴
2	5 ms/step	7.0668e ⁻⁰⁴	5 ms/step	0.0019	5 ms/step	6.3363e ⁻⁰⁴
3	6 ms/step	7.5213e ⁻⁰⁴	5 ms/step	0.0014	5 ms/step	3.6412e⁻⁰⁴
4	8 ms/step	0.0015	7 ms/step	0.0011	13 ms/step	9.0289e ⁻⁰⁴
5	4 ms/step	0.0015	6 ms/step	7.7499e⁻⁰⁴	6 ms/step	5.9736e ⁻⁰⁴
6	6 ms/step	0.0046	25 ms/step	0.0044	4 ms/step	0.0051

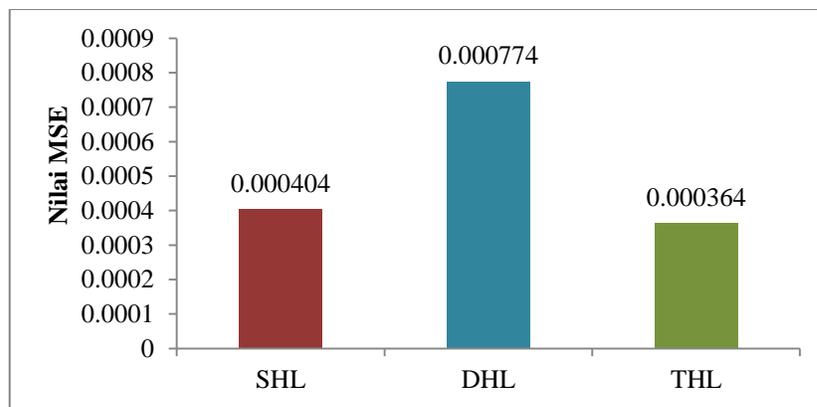
Catatan: SHL= Satu hidden layer; DHL= Dua hidden layer; THL: Tiga hidden layer

Tabel 7.1 menunjukkan bahwa nilai MSE dan waktu konvergensi dari masing-masing model (SHL, DHL, dan THL) cukup bervariasi. Di tinjau dari hasil nilai MSE, THL merupakan model terbaik dengan nilai MSE terkecil dibandingkan dengan model lainnya (DHL dan THL) dengan nilai MSE sekitar $3.6412e^{-04}$. Sedangkan, jika ditinjau dari waktu konvergensinya menunjukkan bahwa DHL merupakan model dengan waktu konvergensi lebih lama dibandingkan dengan model lainnya (SHL dan THL) dengan waktu konvergensi sekitar 25 ms/step . Hal ini biasanya disebut dengan *overfitting* atau *underfitting*. Ying, (2019) menjelaskan bahwa biasanya *overfitting* terjadi disebabkan oleh proses dari model yang dirancang mempelajari data secara menyeluruh, detail, dan data yang tidak terlihat atau tidak dikenali pada proses sebelumnya. Sedangkan, Badieah *dkk* (2016) menyatakan bahwa *overfitting* pada saat pemrosesan data terjadi disebabkan oleh waktu konvergensi yang terlalu lama. Hal ini menunjukkan bahwa model yang dirancang terlampaui jauh dalam mengingat bentuk data dalam kumpulan data pelatihan dan tidak dapat menggeneralisasi data baru.

Proses evaluasi atau pengujian arsitektur dilakukan untuk memvalidasi keakuratan implementasi model.

Selanjutnya, evaluasi model dilaksanakan untuk proses validasi performa model dalam memprediksi harga *cryptocurrency*. Evaluasi dilakukan untuk mengetahui kinerja model yang digunakan untuk perbandingan antar model dan antara data aktual dan data target berdasarkan nilai MSE. Mishra *dkk* (2018)

menyatakan bahwa hasil pada suatu proses pelatihan dengan akurasi yang tinggi akan cenderung memberikan perkiraan hasil yang optimis. Namun jika hasil evaluasi model menunjukkan performa yang belum efektif, maka sebaiknya dibiarkan. Hasil evaluasi model ANN dengan algoritma *backpropagation* menandakan bahwa arsitektur SHL secara umum dapat berkinerja lebih baik dibandingkan arsitektur DHL, dan arsitektur THL merupakan arsitektur dengan kinerja terbaik diantara keduanya (SHL dan DHL). Presentasi perbandingan antar arsitektur model ditunjukkan pada Gambar 7.1.

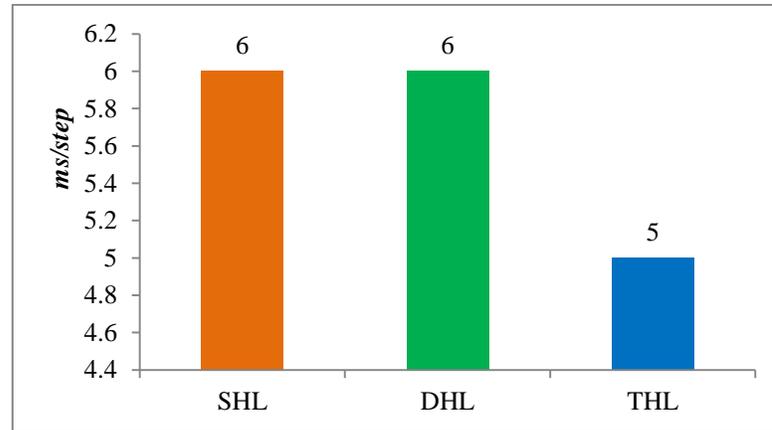


Catatan: SHL= Satu *hidden layer*; DHL= Dua *hidden layer*; THL: Tiga *hidden layer*

Gambar 7.1 Perbandingan tingkat performa terbaik arsitektur model ANN

Gambar 7.1 menunjukkan bahwa strategi ketiga dengan tiga *hidden layer* (THL) merupakan arsitektur model dengan tingkat kinerja terbaik dibandingkan arsitektur model lainnya (SHL dan DHL). Hal ini ditunjukkan melalui proses pengujian pada pelatihan **BP-3C** dengan nilai MSE sekitar $3.6412e^{-04}$. Sedangkan strategi pertama dengan satu *hidden layer* SHL menunjukkan performa terbaiknya melalui proses pengujian pada pelatihan **BP-A1**, dengan nilai MSE sekitar $4.0431e^{-04}$. Kemudian arsitektur DHL menunjukkan performa terbaiknya melalui proses pengujian pada pelatihan **BP-2E**, dengan nilai MSE sekitar $7.7499e^{-04}$. Meski prediksi harga *cryptocurrency* tidak bisa mencapai target atau harga sebenarnya, namun polanya menunjukkan kesamaan. Selanjutnya waktu konvergensi masing-

masing proses tersebut sebesar 6 *ms/step* pada strategi pertama dan kedua dan mencapai 5 *ms/step* pada strategi ketiga dapat dilihat pada Gambar 7.2.



Catatan: SHL= Satu *hidden layer*; DHL= Dua *hidden layer*; THL: Tiga *hidden layer*

Gambar 7.2 Perbandingan waktu konvergensi selama proses pelatihan

Selain itu, banyak faktor yang dapat mempengaruhi volatilitas harga *cryptocurrency* pada kapitalisasi pasar kripto. Anomali volatilitas harga *cryptocurrency* disebabkan oleh faktor tren pasar pada kapitalisasi pasar yang mempengaruhinya. Menurut Ramadhani (2022) ada empat Faktor yang mempengaruhi volatilitas harga *cryptocurrency*, antara lain sebagai berikut:

1. Fluktuasi harga dan likuiditas berdasarkan penawaran dan permintaan.
2. Tidak ada intervensi dari pemerintah.
3. Jumlah permintaan dan penawaran.
4. Standar komoditas.

Prediksi harga *cryptocurrency* dengan parameter tanggal, pembukaan, tertinggi, terendah, penutupan, penyesuaian penutupan, dan *Volume* merupakan parameter data harga *cryptocurrency* dalam kapitalisasi pasar. Namun, terdapat faktor lain yang dapat mempengaruhi naik turunnya pada harga tersebut. Hal ini dapat diartikan bahwa banyaknya permintaan dan penawaran dapat menaikkan dan menurunkan harga harian *cryptocurrency* yang dapat dilihat pada Tabel 7.2.

Tabel 7.2 Faktor naik turunnya harga *cryptocurrency*

Penawaran		Permintaan	
Harga(Rp)	Jumlah (Rp)	Harga(Rp)	Jumlah (Rp)
423.350.000, -	6.194.165.008, -	423.360.000, -	281.826.518, -
423.340.000, -	5.740.490, -	423.370.000, -	103.141.399, -
423.330.000, -	172.930.305, -	423.380.000, -	4.504.763, -
423.320.000, -	783.019.237, -	423.390.000, -	17.570.684, -
423.310.000, -	415.013.124, -	423.400.000, -	911.135.629, -
423.300.000, -	590.571.228, -	423.410.000, -	589.869.407, -
423.290.000, -	486.127.400, -	423.420.000, -	620.864.980, -
423.280.000, -	2.648.192.060, -	423.430.000, -	431.242.283, -

Catatan: Sampel data transaksi *cryptocurrency*

Cryptocurrency adalah metode Untuk membentuk "koin" virtual dan memberikan kepemilikan dan transaksi yang aman menggunakan teknik kriptografi. Transaksi digital dapat berupa pembayaran non tunai maupun pembayaran non tunai yang dilakukan secara virtual dengan menggunakan website atau aplikasi pada smartphone dan perangkat lainnya. Juga disertakan metode dan alat pembayaran yang dilakukan menggunakan mata uang digital berikutnya dalam Bahasa Arab yang disebut Al-Sharf. Al-Sharf adalah menjual membeli suatu mata uang dengan mata uang yang lain. Dalam QS Al- Baqarah ayat 275:

أَلَّذِينَ يَأْكُلُونَ أَرْبَاؤًا لَا يَقُومُونَ إِلَّا كَمَا يَقُومُ الَّذِي يَتَخَبَّطُهُ الشَّيْطَانُ مِنَ الْمَسِّ ذَلِكَ بِأَنَّهُمْ قَالُوا إِنَّمَا بَيْعٌ مِثْلُ بَيْعِ الرَّبَا وَأَحَلَّ اللَّهُ الْبَيْعَ وَحَرَّمَ الرِّبَا فَمَنْ جَاءَهُ مَوْعِظَةٌ مِنْ رَبِّهِ فَانْتَهَى فَلَهُ مَا سَلَفَ وَأَمْرُهُ إِلَى اللَّهِ وَمَنْ عَادَ فَأُولَئِكَ أَصْحَابُ النَّارِ هُمْ فِيهَا خَالِدُونَ ٢٧٥

Artinya: *Orang yang mengkonsumsi bunga akan berdiri 'pada Hari Kiamat' seperti orang yang menjadi gila karena sentuhan setan. Hal ini karena mereka mengatakan, "Perdagangan tidak ada bedanya dengan bunga." Namun Allah menghalalkan jual beli dan mengharamkan bunga. Siapa pun yang menahan diri, setelah mendapat teguran dari Tuhannya, niscaya ia akan mempertahankan apa yang telah ia peroleh sebelumnya, dan urusannya diserahkan kepada Allah. Adapun orang-orang yang bertahan, maka merekalah yang akan menjadi penghuni Neraka. Mereka akan berada di sana selamanya. Al-Baqarah [2]:275.*

Allah juga melarang memakan harta orang lain dengan cara yang salah _yaitu dengan tanpa ada hak yang dibolehkan_ Untuk memakannya, dan sebagainya. Itu adalah kebatilan berdasarkan ijma ' ulama '. Sesuai dengan firman Allah dalam QS An – Nisa ayat 29:

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ ۗ وَلَا تَقْتُلُوا
 أَنْفُسَكُمْ ۗ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

Artinya: *Wahai orang-orang yang beriman! Janganlah saling memakan harta orang lain secara haram, tetapi berdaganglah atas dasar kemauan bersama. Dan jangan bunuh 'satu sama lain atau' dirimu sendiri. Sesungguhnya Allah Maha Penyayang kepadamu . An-Nisa [4]:29.*

Para ulama telah menyepakati diperbolehkannya akad jual beli. Dalam ijma'nya beliau memberikan hikmah bahwa kebutuhan manusia itu berkaitan dengan sesuatu yang dimiliki orang lain dan bahwa kepemilikan atas sesuatu itu tidak akan diberikan secara cuma-cuma, harus ada imbalan sebagai balasannya sehingga dengan ketentuan membeli dan menjual ini merupakan salah satu cara untuk mewujudkan keinginan dan juga kebutuhan manusia karena manusia tidak bisa hidup sendiri.

Selanjutnya, transaksi al-sharf merupakan transaksi yang diharamkan dalam Islam sepanjang memenuhi seluruh syarat dan rukun, baik yang disebutkan dalam Al-Qur'an, hadis, maupun ijma' ulama. Transaksi al-sharf ini diharamkan karena Nabi Muhammad SAW membolehkan jual beli barang dagangan riba bila jenisnya sama dan ukurannya sama, atau jenisnya berbeda meskipun ada perbedaan besaran secara tunai. Dasar hukum diperbolehkannya al-Sarf adalah Alquran dan hadis. Allah berfirman dalam (QS. Al-Baqarah ayat 275):

وَأَحَلَّ اللَّهُ الْبَيْعَ وَحَرَّمَ الرِّبَا

Artinya : *Dan Allah menghalalkan jual beli dan mengharamkan riba. Al-Baqarah [2]:275*

Namun berbeda dengan jual beli *cryptocurrency* yang dilihat dari segi keselarasan, dan ketentuan dalam aturan jual beli online dapat dikatakan telah terpenuhi; ada penjual dan pembeli. Demikian pula akad hanya dapat dilakukan secara tertulis atau mengikuti langkah-langkah pembelian yang ditentukan atas kemauan sendiri. Karena pembeli sudah melalui semua proses maka transaksi

berhasil. Namun karena adanya unsur gharâr yaitu jual beli yang mengandung unsur ketidakpastian, ambiguitas, dan penipuan yang dapat merugikan salah satu pihak, maka transaksi seperti ini tergolong transaksi yang mengandung gharâr yang dilarang dalam Islam dan harus dilakukan. ditinggalkan.

Berdasarkan hasil konjungsi astral, para ulama Komisi Fatwa Indonesia ke-7 pun memutuskan mengenai unsur gharar dalam transaksi jual beli sebagaimana kita lihat pada firman Allah dalam Al-Qur'an surat Al- Baqarah ayat 278:

يَا أَيُّهَا الَّذِينَ ءَامَنُوا **dan** تَقُوا اللَّهَ **dan** وَذَرُوا مَا بَقِيَ مِنَ الرِّبَا إِن كُنْتُمْ مُؤْمِنِينَ ٢٧٨

Artinya: *Wahai orang-orang yang beriman! Takutlah kepada Allah, dan tinggalkan bunga yang belum terbayar jika Anda adalah orang yang beriman 'sejati'.* Al-Baqarah [2]:278.

Kemudian dalam firman Allah QS. Al-Baqarah ayat 188:

وَلَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِ اَلْبَطْلِ وَتُدُلُّوْا بِهَا إِلَى اَلْحُكْمِ لِتَأْكُلُوا فَرِيقًا مِّنْ أَمْوَالِ النَّاسِ بِ اَلْإِثْمِ وَأَنْتُمْ تَعْلَمُونَ ١٨٨

Artinya: *Janganlah kita saling memakan harta orang lain secara tidak adil, dan jangan pula dengan sengaja menyuap penguasa untuk memakan sebagian harta orang lain, padahal kita tahu bahwa hal itu adalah dosa.* Al-Baqarah [2]:188.

Selanjutnya pada Firman Allah QS. An- Nisa ayat 29:

يَا أَيُّهَا الَّذِينَ ءَامَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَ كُمْ بِ اَلْبَطْلِ إِلاَّ أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ ۚ وَلَا تَقْتُلُوا أَنْفُسَكُمْ ۚ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا ٢٩

Artinya: *Hai orang-orang yang beriman! Janganlah saling memakan harta orang lain secara haram, tetapi berdaganglah atas dasar kemauan bersama. Dan jangan bunuh 'satu sama lain atau' dirimu sendiri. Sesungguhnya Allah Maha Penyayang kepadamu.* An-Nisa [4]:29.

Di sisi lain, Majelis Ulama Indonesia telah mengeluarkan fatwa terkait jual beli *cryptocurrency* dengan Nomor:116/DSNMUI/IX/2017 menyatakan bahwa transaksi jual beli mata uang pada prinsipnya dapat dengan memenuhi ketentuan antara lain:

1. Tidak Untuk spekulasi,
2. Ada keperluan transaksi atau Untuk tabungan,
3. Jika transaksi dilakukan untuk melihat jenis uang maka nilainya harus sama dan dalam arti tunai,
4. Jika berbeda jenis maka harus dilakukan dengan tandai kurs yang berlaku saat transaksi dilakukan dan secara tunai.

Ketentuan pada empat hal di atas yang masih berlaku pada kripto adalah sistem spekulasi sehingga mengandung unsur riba dan *gharar*. Allah SWT berfirman dalam surat Al- Maidah ayat 90:

يَا أَيُّهَا الَّذِينَ ءَامَنُوا إِنَّمَا الْخَمْرُ وَالْأَلْمِيسِرُ وَالْأَنْصَابُ وَالْأَزْلَمُ رِجْسٌ مِّنْ عَمَلِ الشَّيْطَانِ فَآ
جْتَنِبُوهُ لَعَلَّكُمْ تُفْلِحُونَ ٩٠

Artinya: *Wahai orang-orang yang beriman! Minuman keras, perjudian, penyembahan berhala, dan undian untuk mengambil keputusan, semuanya merupakan perbuatan jahat Setan. Jadi jauhi mereka agar Anda bisa sukses. Al-Maidah [5]:90.*

Ditinjau dari sisi MUI transaksi yang digunakan dan investasi *cryptocurrency* lebih mendekati *gharar* atau spekulasi yang merugikan pihak lain karena kendali dan kebenarannya. Belum ada jaminan yang secara resmi. Namun jika digunakan untuk ilmu pengetahuan sangat bermanfaat baik bagi praktisi maupun peneliti sebagaimana dijelaskan dalam Qs: Al-Imron ayat 191.

أَلَّذِينَ يَذْكُرُونَ اللَّهَ قِيَمًا وَقُعُودًا وَعَلَىٰ جُنُوبِهِمْ وَيَتَفَكَّرُونَ فِي خَلْقِ السَّمٰوٰتِ وَالْأَرْضِ رَبَّنَا مَا
خَلَقْتَ هٰذَا بَطِيْلًا سُبْحٰنَكَ فَقِنَا عَذَابَ النَّارِ ١٩١

Artinya: *‘Mereka’ adalah orang-orang yang mengingat Allah sambil berdiri, duduk, dan berbaring miring, serta merenungkan penciptaan langit dan bumi ‘dan berdoa’, “Ya Tuhan kami! Anda tidak menciptakan ‘semuanya’ ini tanpa tujuan. Kemuliaan bagimu ! Lindungi kami dari siksa api neraka. Al-'Imron [3]:191.*

Prediksi harga *cryptocurrency* merupakan hasil proses pengamatan kondisi harga pada waktu tertentu. Perkiraan harga yang sah boleh saja, namun konsensus para ulama menyatakan haram jika perkiraan tersebut berasal dari dukun atau dukun

yang bersifat gaib. Estimasi merupakan hasil pengamatan elemen harga *cryptocurrency* seperti harga pembukaan, harga tertinggi, harga terendah, harga penutupan, penyesuaian harga penutupan, dan harga penutupan. Perkiraan harga *cryptocurrency* berbeda dengan prediksi para dukun dan paranormal yang mendasarkan pada wawasan magis saat melakukan prakiraan. Oleh sebab itu, proses prediksi dalam penelitian masih dalam koridor berdasarkan hukum agama. Sebab, hasil penelitian prediksi harga *cryptocurrency* didasarkan pada kondisi atau keadaan yang bisa mempunyai nilai salah dan benar, sehingga tidak tergolong ilmu magis. Jadi, semua kejadian bergantung pada keputusan Tuhan. Oleh karena itu, manusia dilarang untuk percaya diri ketika melakukan prediksi tentang apapun. Hal ini sesuai dengan firman Allah dalam Al-Qur'an, Surat Al- An'am Ayat 62:

ثُمَّ رُدُّوا إِلَى اللَّهِ مَوْلَاهُمْ الْحَقَّ ۗ لَا إِلَهَ إِلَّا لَهُ أُلْحُكُمُ ۖ وَهُوَ أَسْرَعُ الْحَاسِبِينَ ٦٢

Artinya: *Kemudian mereka 'semua' kembali kepada Allah—Guru Sejati mereka. Penghakiman hanya milik-Nya. Dan Dialah Yang Maha Cepat Menghitungnya. Al-An'am [6]:62.*

BAB VIII

KESIMPULAN

8.1. Kesimpulan

Berdasarkan hasil pelatihan dan pengujian arsitektur model ANN dengan algoritma *backpropagation* yang terdiri dari tiga strategi, dengan menentukan setiap atribut sebagai variabel target, jumlah node pada setiap *hidden layer*, dan jumlah epoch, maka dapat ditarik kesimpulan dari penelitian ini adalah:

- a. Penentuan atribut sebagai variabel target pada setiap arsitektur model sangat mempengaruhi proses penghitungan prediksi harga *cryptocurrency* baik pada proses pelatihan maupun pengujian. Hal ini ditandai dengan waktu ketika proses mencapai konvergensi dengan kecepatan sekitar 6 *ms/step* pada strategi pertama dan kedua. Sedangkan strategi ketiga hanya membutuhkan waktu sekitar 5 *ms/step* untuk mencapai konvergensi.
- b. THL pada pelatihan **BP-3C** menjadi strategi atau model yang dipilih dan dapat digunakan untuk memprediksi harga *cryptocurrency* karena menunjukkan performa terbaik dibandingkan arsitektur model lainnya (SHL dan DHL) dengan nilai MSE sekitar $3.6412e^{-04}$ atau dengan nilai akurasi sekitar 99.97%.

8.2. Keterbatasan dan saran

Berdasarkan hasil nilai MSE pada proses pengujian menunjukkan bahwa ANN dengan algoritma *backpropagation* cenderung baik sebagai model untuk memprediksi harga *cryptocurrency*. Namun terdapat keterbatasan terutama terkait penggunaan faktor-faktor yang mempengaruhi proses prediksi yang dilakukan dan penggunaan data penelitian. Oleh karena itu, perlu menambahkan faktor permintaan

dan penawaran ke dalam proses prediksi, serta menggunakan *cryptocurrency* lain seperti DCT dan ETH dalam penelitian di masa depan.

DAFTAR PUSTAKA

- Aggarwal, S., & Kumar, N. (2021). Cryptocurrencies. In *Advances in Computers* (Vol. 121, pp. 227–266). Elsevier.
- Asenahabi, B. M. (2019). Basics of research design: A guide to selecting appropriate research design. *International Journal of Contemporary Applied Researches*, 6(5), 76–89.
- Ausop, A. Z., & Aulia, E. S. N. (2018). Teknologi *Cryptocurrency* Bitcoin Dalam Transaksi Bisnis Menurut Syariat Islam. *Jurnal Sositologi*, 17(1), 74–92.
- Badieah, B., Gernowo, R., & Surarso, B. (2016). Metode Jaringan Syaraf Tiruan Untuk Prediksi Performa Mahasiswa Pada Pembelajaran Berbasis Problem Based Learning (PBL). *JSINBIS (Jurnal Sistem Informasi Bisnis)*, 6(1), 46–58.
- Cavalli, S., & Amoretti, M. (2021). CNN-based multivariate data analysis for bitcoin trend prediction. *Applied Soft Computing*, 101, 107065.
- Charandabi, S. E., & Kamyar, K. (2021). Prediction of *cryptocurrency* price index using artificial neural networks: a survey of the literature. *European Journal of Business and Management Research*, 6(6), 17–20.
- de Souza, M. J. S., Almudhaf, F. W., Henrique, B. M., Negredo, A. B. S., Ramos, D. G. F., Sobreiro, V. A., & Kimura, H. (2019). Can artificial intelligence enhance the Bitcoin bonanza. *The Journal of Finance and Data Science*, 5(2), 83–98.
- Fageh, A., & Iman, A. K. N. (2021). *Cryptocurrency* as Investment in Commodity Futures Trading in Indonesia; Based on Maqās id al-Sharī'ah Approach. *Jurnal Hukum Islam*, 19(2), 175–192.
- Farell, R. (2015). *An analysis of the cryptocurrency industry*.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Applications and Algorithms*. Prentice-Hall International, Inc.
- Gopal, N., & Senthilkumar, K. S. (2020). Predicting bitcoin prices-ANN approach. *International Journal of Electronic Finance*, 10(1–2), 67–78.
- Lama, A., Singh, K. N., Gurung, B., & Rathod, S. (2021). *Parameter estimation of time series models using Bayesian technique*.
- Li, X., & Wang, C. A. (2017). The technology and economic determinants of *cryptocurrency* exchange rates: The case of Bitcoin. *Decision Support Systems*, 95, 49–60.

- Lim, W. T., Wang, L., Wang, Y., & Chang, Q. (2016). Housing price prediction using neural networks. *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 518–522.
- Margono, S. (2005). *Metodologi penelitian pendidikan*.
- Mishra, N., Soni, H. K., Sharma, S., & Upadhyay, A. K. (2018). Development and analysis of artificial neural network models for rainfall prediction by using time-series data. *International Journal of Intelligent Systems and Applications*, 12(1), 16.
- Mulyo, H. (2016). Statistical Technique Dan Parameter Optimization Pada Neural Network Untuk Forecasting Harga Emas. *Jurnal Disprotek*, 7(2).
- Nakamoto, S. (2013). Bitcoin: A peer-to-peer electronic cash system. Manubot. 2019; Lemieux, P., Who Is Satoshi Nakamoto. *Regulation*, 36(3).
- Nayak, S. K., Nayak, S. C., & Das, S. (2021). Modeling and forecasting *cryptocurrency* closing prices with rao algorithm-based artificial neural networks: A machine learning approach. *FinTech*, 1(1), 47–62.
- Othman, A. H. A., Kassim, S., Rosman, R. Bin, & Redzuan, N. H. B. (2020). Prediction accuracy improvement for Bitcoin market prices based on symmetric volatility information using artificial neural network approach. *Journal of Revenue and Pricing Management*, 19(5), 314–330.
- PRASETYO, A. T. R. I. (2017). *PENGGUNAAN JARINGAN SARAF TIRUAN (ANN) UNTUK PREDIKSI KETIDAKSEIMBANGAN TEGANGAN PADA SISTEM TENAGA LISTRIK*. Universitas Muhammadiyah Semarang.
- Radityo, A., Munajat, Q., & Budi, I. (2017). Prediction of Bitcoin exchange rate to American dollar using artificial neural network methods. *2017 International Conference on Advanced Computer Science and Information Systems (ICACISIS)*, 433–438.
- Ramadhani, I. (2022). Analisis Faktor-Faktor Yang Mempengaruhi Harga *Cryptocurrency (Cryptocurrency)* Di Indonesia Studi Pada Bitcoin. *EKOMA: Jurnal Ekonomi, Manajemen, Akuntansi*, 2(1), 46–54.
- Rourke, L., Anderson, T., Garrison, D. R., & Archer, W. (2001). Methodological issues in the content analysis of computer conference transcripts. *International Journal of Artificial Intelligence in Education*, 12, 8–22.
- Safari, A., & Ghavifekr, A. A. (2021). International stock index prediction using artificial neural network (ANN) and Python programming. *2021 7th*

International Conference on Control, Instrumentation and Automation (ICCIA), 1–7.

- Setyaningsih, F. (2015). PERBANDINGAN ALGORITMA GENETIKA DAN METODE STATISTIK ARIMA UNTUK PREDIKSI DATA TIME SERIES (Studi Kasus: Kunjungan Museum di Kota Yogyakarta). *SEMIRATA* 2015, 5(1).
- Sileyew, K. J. (2019). Research design and methodology. *Cyberspace*, 1–12.
- Sivanandam, S., & Paulraj, M. (2009). *Introduction to artificial neural networks*. Vikas Publishing House.
- Thomas, A. J., Petridis, M., Walters, S. D., Gheytaasi, S. M., & Morgan, R. E. (2017). Two *hidden layers* are usually better than one. *Engineering Applications of Neural Networks: 18th International Conference, EANN 2017, Athens, Greece, August 25–27, 2017, Proceedings*, 279–290.
- Wijaya, Y. B., Kom, S., & Napitupulu, T. A. (2010). Stock price prediction: comparison of Arima and artificial neural network methods-An Indonesia Stock's Case. *2010 Second International Conference on Advances in Computing, Control, and Telecommunication Technologies*, 176–179.
- Xiao, D., Li, B., & Mao, Y. (2017). A multiple *hidden layers* extreme learning machine method and its application. *Mathematical Problems in Engineering*, 2017.
- Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168, 22022.
- Yiying, W., & Yeze, Z. (2019). *Cryptocurrency* price analysis with artificial intelligence. *2019 5th International Conference on Information Management (ICIM)*, 97–101.

LAMPIRAN

Lampiran 1

Tabel hasil uji coba

Nama Pelatihan	Arsitektur	Waktu konvergensi	MSE
BP-1A	7-5-1	6 ms/step	4.0431e⁻⁰⁴
BP-1B	7-5-1	5 ms/step	7.0668e ⁻⁰⁴
BP-1C	7-5-1	6 ms/step	7.5213e ⁻⁰⁴
BP-1D	7-5-1	8 ms/step	0,0015
BP-1E	7-5-1	4 ms/step	0,0015
BP-1F	7-5-1	6 ms/step	0,0046
BP-2A	7-10-5-1	5 ms/step	8.8644e ⁻⁰⁴
BP-2B	7-10-5-1	5 ms/step	0,0019
BP-2C	7-10-5-1	5 ms/step	0,0014
BP-2D	7-10-5-1	7 ms/step	0,0011
BP-2E	7-10-5-1	6 ms/step	7.7499e⁻⁰⁴
BP-2F	7-10-5-1	25 ms/step	0,0044
BP-3A	7-12-10-5-1	3 ms/step	8.7154e ⁻⁰⁴
BP-3B	7-12-10-5-1	5 ms/step	6.3363e ⁻⁰⁴
BP-3C	7-12-10-5-1	5 ms/step	3.6412e⁻⁰⁴
BP-3D	7-12-10-5-1	13 ms/step	9.0289e ⁻⁰⁴
BP-3E	7-12-10-5-1	6 ms/step	5.9736e ⁻⁰⁴
BP-3F	7-12-10-5-1	4 ms/step	0,0051